

**TESIS**  
**DETEKSI PENYAKIT TANAMAN TEBU BERDASARKAN**  
**CITRA DAUN MENGGUNAKAN METODE**  
**CONVOLUTIONAL NEURAL NETWORK**



Disusun oleh:

Nama : Arflan Hendro Priyono  
NIM : 21.52.2123  
Konsentrasi : Business Intelligence

**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**  
**2026**

**TESIS**

**DETEKSI PENYAKIT TANAMAN TEBU BERDASARKAN  
CITRA DAUN MENGGUNAKAN METODE  
CONVOLUTIONAL NEURAL NETWORK**

**DETECTION OF SUGARCANE PLANT DISEASES BASED ON  
LEAF IMAGE USING CONVOLUTIONAL NEURAL  
NETWORK**

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana  
Program Studi Teknik Informatika



Disusun oleh:

**Nama** : Arflan Hendro Priyono  
**NIM** : 21.52.2123  
**Konsentrasi** : Business Intelligence

**FAKULTAS ILMU KOMPUTER  
UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA  
2026**

**HALAMAN PERSETUJUAN**  
**DETEKSI PENYAKIT TANAMAN TEBU BERDASARKAN CITRA DAUN**  
**MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK**

**DETECTION OF SUGARCANE PLANT DISEASES BASED ON LEAF**  
**IMAGE USING CONVOLUTIONAL NEURAL NETWORK**

Yang disusun dan diajukan oleh

**Arfian Hendro Priyono**

**21.52.2123**

telah disetujui oleh Dosen Pembimbing Tesis  
pada tanggal 21 Juli 2025

**Pembimbing Utama**



**Prof. Dr. Ema Utami, S.Si., M.Kom**

**NIK. 190302037**

**Pembimbing Pendamping**



**Dhani Ariatanto, M.Kom., Ph.D**

**NIK. 190302197**

**HALAMAN PENGESAHAN**  
**DETEKSI PENYAKIT TANAMAN TEBU BERDASARKAN CITRA DAUN**  
**MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK**

**DETECTION OF SUGARCANE PLANT DISEASES BASED ON LEAF**  
**IMAGE USING CONVOLUTIONAL NEURAL NETWORK**

Yang disusun dan diajukan oleh

**Arfian Hendro Priyono**

**21.52.2123**

Telah dipertahankan di depan Dewan Penguji  
pada tanggal 06 Agustus 2025

**Susunan Dewan Penguji**

**Nama Penguji**

**Tanda Tangan**

**Hanif Al Fatta, S.Kom., M.Kom., Ph.D**  
**NIK. 190302096**

**M. Hanafi, S.Kom., M.Eng., Ph.D**  
**NIK. 190302024**

**Prof. Dr. Ema Utami, S.Si., M.Kom**  
**NIK. 190302037**

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer  
Tanggal 06 Agustus 2025.

**DEKAN FAKULTAS ILMU KOMPUTER**



**Prof. Dr. Kusrini, M.Kom.**  
**NIK. 190302106**

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Arfian Hendro Priyono

NIM : 21.52.2123

Menyatakan bahwa Tesis dengan judul berikut:

### **Deteksi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network**

Dosen Pembimbing Utama : Prof. Dr. Ema Utami, S.Si., M.Kom.

Dosen Pembimbing Pendamping : Dhani Ariatmanto, M.Kom., Ph.D

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 06 Agustus 2025

Menyatakan,



  
Arfian Hendro Priyono


## HALAMAN PERSEMBAHAN

Segala puji bagi Allah SWT, tiada daya dan upaya melainkan atas pertolongan dan karunia-Nya sehingga penulis dapat menyelesaikan penelitian tugas akhir ini. Dengan penuh rasa syukur dan bahagia, penulis persembahkan Tesis ini kepada:

1. Istri tercinta Risca Yunita yang senantiasa memberikan dukungan serta selalu mengingatkan saya siang maupun malam, serta Jagoan-jagoan tercinta Arshad Keanu Adhyatsa Priyono dan Alceo Khael Arzanka Priyono yang senantiasa menjadi penyemangat, semoga selalu dalam lindungan Allah SWT.
2. Keempat orang tua penulis, Bapak Dwi Heri Priyono Dan Ibu Endang Susiani dan juga Bapak Sukimin Dan Almarhum Ibu Saroh Pariyanti Lestari dan juga Ketiga Adik saya Pangestika Arum Pambudi, Arip Lukito Dan Juga Iik Rico Bretly yang senantiasa memberikan semangat dan doa, semoga selalu dalam lindungan Allah SWT.
3. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom. dan Bapak Dhani Ariatmanto, M.Kom., Ph.D. yang telah memberikan bimbingan dan dorongan selama pelaksanaan penelitian tugas akhir ini.
4. Seluruh keluarga, teman-teman MTI AMIKOM, dan semua pihak yang menginspirasi penulis dalam penyelesaian tugas akhir ini yang tidak bisa penulis sebutkan satu persatu.

## HALAMAN MOTTO

"Disiplin diri adalah sebenar-benarnya wujud kebebasan yang hakiki."  
"Tiada Lain Selain Allah SWT, Kita Meminta."



## KATA PENGANTAR

Puji syukur saya panjatkan ke hadirat Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya sehingga saya dapat menyelesaikan tesis ini yang berjudul **“Deteksi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network”** sebagai salah satu syarat untuk memperoleh gelar **Magister** pada program studi **S2 Teknik Informatika** di **Universitas Amikom Yogyakarta**.

Tesis ini tidak akan terselesaikan tanpa adanya dukungan, bimbingan, dan bantuan dari berbagai pihak. Tesis ini diajukan sebagai bukti kemampuan penulis dalam melakukan penelitian dan pengembangan ilmu pengetahuan di bidang *Computer Science / Informatic Engineering*. Oleh karena itu, pada kesempatan ini saya ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT, atas rahmat dan karunia-Nya yang tiada terkira.
2. Istri tercinta Risca Yunita yang senantiasa memberikan dukungan serta selalu mengingatkan saya siang maupun malam, serta Jagoan-jagoan tercinta Arshad Keanu Adhyatsa Priyono dan Alceo Khaal Arzanka Priyono yang senantiasa menjadi penyemangat, semoga selalu dalam lindungan Allah SWT.
3. Keempat orang tua penulis, Bapak Dwi Heri Priyono Dan Ibu Endang Susiani dan juga Bapak Sukimin Dan Almarhum Ibu Saroh Pariyanti Lestari dan juga Ketiga Adik saya Pangestika Arum Pambudi, Arip Lukito Dan Juga Iik Rico Bretly yang senantiasa memberikan semangat dan doa, semoga selalu dalam lindungan Allah SWT.
4. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom. dan Bapak Dhani Ariatmanto, M.Kom., Ph.D. yang telah dengan sabar membimbing, mengarahkan, dan memberikan masukan berharga dalam penyusunan tesis ini.
5. Segenap Dosen di Program Studi Magister Teknik Informatika yang telah dengan tulus membagikan ilmu pengetahuan dan pengalamannya kepada penulis.
6. Teman-Teman Seangkatan, yang selalu memberikan semangat, dukungan, dan bantuan dalam suka dan duka selama masa perkuliahan.

7. Semua Pihak yang Berperan Serta dalam menyelesaikan tesis ini, baik secara langsung maupun tidak langsung.

Penulis berharap semoga tesis ini dapat memberikan manfaat bagi penulis, pembaca, dan perkembangan ilmu pengetahuan, khususnya di bidang *Computer Science / Informatic Engineering*.

Yogyakarta, 06 Agustus 2025


Arfian Hendro Priyono



## DAFTAR ISI


HALAMAN JUDUL .....	ii
HALAMAN PERSETUJUAN .....	iii
HALAMAN PENGESAHAN .....	iv
HALAMAN PERNYATAAN KEASLIAN PENULIS .....	v
HALAMAN PERSEMBAHAN .....	vi
HALAMAN MOTTO .....	vii
HALAMAN KATA PENGANTAR.....	viii
DAFTAR ISI.....	ix
INTISARI .....	xi
ABSTRACT.....	xiii
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	9
1.3 Batasan Masalah.....	10
1.4 Tujuan Penelitian.....	10
1.5 Manfaat Penelitian.....	11
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>12</b>
2.1 Tinjauan Pustaka .....	12
2.2 Keaslian Penelitian.....	16
2.3 Landasan Teori.....	26
<b>BAB III METODE PENELITIAN .....</b>	<b>33</b>
3.1 Jenis Sifat Dan Pendekatan .....	33
3.2 Metode Analisis Data .....	34
3.3 Alur Penelitian .....	35
3.4 Penjelasan Alur Penelitian.....	36
<b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....</b>	<b>38</b>
4.1 Pengumpulan Data .....	38
4.2 Perbandingan VGG 16 Dan Konvensional .....	38
4.3 Analisis Data.....	40

<b>BAB V PENUTUP</b> .....	57
5.1 Kesimpulan .....	57
5.2 Saran.....	58
<b>DAFTAR PUSTAKA</b>	



## DAFTAR LAMPIRAN

Lampiran 1 Dataset .....	62
Lampiran 2 Hasil Train .....	62
Lampiran 3 Tabel Pemodelan.....	63
Lampiran 4 Hasil Epoch.....	63



## INTISARI

Sebagai bahan utama pembuatan gula dan etanol, tebu menjadi salah satu komoditas perkebunan yang sangat penting. Meski demikian, masa tanamnya yang cukup lama, sekitar satu tahun, menjadikan tanaman ini lebih rentan terhadap penyakit. Penggunaan teknologi *machine learning* telah diterapkan dalam identifikasi daun tebu, salah satunya dengan metode pre-processing, dan pengembangan model klasifikasi penyakit daun tebu, dengan pendekatan *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM), namun memiliki kelemahan pada akurasi. Untuk itu penting untuk meningkatkan akurasi identifikasi dengan VGG-16. Tujuan dari penelitian ini meningkatkan akurasi untuk identifikasi penyakit daun padi dengan menggunakan VGG-16. Dataset yang digunakan 2521 citra daun tebu yang terbagi menjadi lima kelas. Hasil dari penelitian ini terdapat peningkatan akurasi dari 97,78% menjadi 99,14%, terjadi peningkatan sebesar 1,36%.

Kata Kunci: *CNN; Machine learning; Sugarcane leaf disease; VGG-16.*

## ABSTRACT

*As the primary raw material for sugar and ethanol production, sugarcane is a highly significant plantation commodity. However, its relatively long growing period of approximately one year makes it more susceptible to diseases. Machine learning technology has been applied in the identification of sugarcane leaves, including through pre-processing methods and the development of disease classification models using Convolutional Neural Network (CNN) and Support Vector Machine (SVM) approaches. However, these methods exhibit limitations in terms of accuracy. Therefore, improving identification accuracy using VGG-16 is essential. The objective of this study is to enhance the accuracy of sugarcane leaf disease identification by utilizing VGG-16. The dataset consists of 2,521 sugarcane leaf images categorized into five classes. The results of this study indicate an accuracy improvement from 97.78% to 99.14%, reflecting an increase of 1.36%*

**Keywords:** CNN; Machine learning; Sugarcane leaf disease; VGG-16

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Tebu merupakan tanaman yang multifungsi, selain sebagai penghasil gula juga dapat dimanfaatkan sebagai *biofuel*, daunnya bisa menjadi sumber pakan ternak, serasahnya dapat dimanfaatkan sebagai sumber bahan organik yang jika dikembalikan lagi ke tanah dapat meningkatkan kesuburan tanah. Namun demikian, tebu juga rentan terhadap serangan organisme pengganggu tumbuhan ([ditjenbun.pertanian.go.id](http://ditjenbun.pertanian.go.id))

Tanaman tebu (*Saccharum officinarum*) merupakan salah satu komoditas pertanian yang memiliki peranan penting dalam sektor ekonomi, terutama dalam industri gula. Namun, produksi tebu sering kali terancam oleh berbagai penyakit yang dapat mengurangi hasil panen dan kualitas gula. Beberapa penyakit yang umum menyerang tanaman tebu, seperti bercak daun, busuk akar, dan penyakit layu, dapat menyebabkan kerugian yang signifikan bagi petani.

Deteksi dini terhadap penyakit tanaman tebu sangat penting untuk pengelolaan tanaman yang efektif. Metode konvensional dalam mendeteksi penyakit sering kali memerlukan keahlian dan waktu yang banyak, sehingga tidak selalu praktis di lapangan. Dengan perkembangan teknologi, khususnya dalam bidang pengolahan citra dan kecerdasan buatan, terdapat peluang untuk mengembangkan sistem deteksi otomatis yang lebih efisien.

Convolutional Neural Network (CNN) merupakan salah satu pendekatan dalam deep learning yang terbukti efektif dalam analisis citra. Metode ini dapat mengenali pola dan fitur dalam citra dengan akurasi tinggi, sehingga sangat cocok untuk diterapkan dalam deteksi penyakit tanaman. Dengan memanfaatkan CNN, proses identifikasi dan klasifikasi penyakit pada daun tebu dapat dilakukan secara otomatis, cepat, dan akurat.

Penelitian ini bertujuan untuk mengembangkan model deteksi penyakit pada tanaman tebu berdasarkan citra daun menggunakan metode CNN. Diharapkan hasil penelitian ini dapat memberikan kontribusi bagi petani dalam pengelolaan tanaman tebu serta meningkatkan produktivitas dan kualitas hasil panen.

Convolutional Neural Network (CNN) adalah salah satu metode dalam deep learning yang dirancang khusus untuk pengolahan data berbentuk citra. CNN telah menunjukkan kinerja yang luar biasa dalam berbagai tugas pengenalan pola, klasifikasi gambar, dan segmentasi citra. Berbeda dengan jaringan saraf tradisional, CNN memanfaatkan operasi konvolusi yang memungkinkan model untuk mengenali fitur lokal dalam citra, seperti tepi, sudut, dan pola.

#### **Arsitektur CNN yang Berbeda**

1. **LeNet-5:** LeNet-5 adalah salah satu arsitektur CNN pertama yang diperkenalkan oleh Yann LeCun pada tahun 1998. Arsitektur ini terdiri dari beberapa lapisan konvolusi diikuti oleh lapisan subsampling (pooling) dan diakhiri dengan lapisan fully connected. LeNet-5 dirancang untuk pengenalan karakter dan angka, seperti pada sistem pembacaan cek bank.

Meskipun sederhana, LeNet-5 memberikan dasar bagi pengembangan arsitektur CNN yang lebih kompleks.

2. **AlexNet:** Dikenalkan oleh Alex Krizhevsky dan timnya pada tahun 2012, AlexNet mengubah paradigma pengenalan citra dengan memperkenalkan teknik dropout untuk mencegah overfitting dan menggunakan GPU untuk mempercepat pelatihan. AlexNet memiliki delapan lapisan (lima lapisan konvolusi dan tiga lapisan fully connected) dan berhasil memenangkan kompetisi ImageNet, menunjukkan kemampuan CNN dalam menangani dataset besar dan kompleks.
3. **VGGNet:** VGGNet, yang diperkenalkan oleh Visual Geometry Group dari Universitas Oxford, menggunakan lapisan konvolusi dengan ukuran filter yang kecil (3x3) dan struktur yang lebih dalam (hingga 19 lapisan). VGGNet dikenal karena kesederhanaan dan efisiensinya dalam mengekstraksi fitur, yang memungkinkan transfer learning ke berbagai tugas pengenalan citra. Keunggulan arsitektur ini adalah kemampuannya untuk menghasilkan representasi fitur yang sangat baik.
4. **ResNet (Residual Network):** Diperkenalkan oleh Kaiming He dan timnya pada tahun 2015, ResNet mengatasi masalah vanishing gradient yang sering muncul pada jaringan yang sangat dalam. Dengan menggunakan shortcut connections, ResNet memungkinkan informasi dan gradien mengalir lebih bebas di sepanjang jaringan. Arsitektur ini sangat dalam, dengan versi yang mencapai lebih dari 100 lapisan, dan berhasil memenangkan kompetisi ImageNet 2015.

5. **Inception (GoogLeNet):** Inception, atau GoogLeNet, diperkenalkan oleh Google pada tahun 2014. Arsitektur ini inovatif dengan menggabungkan beberapa ukuran filter dalam satu lapisan, yang disebut "inception module". Ini memungkinkan model untuk menangkap fitur dengan berbagai skala dan meningkatkan efisiensi komputasi. Inception juga memiliki pendekatan yang lebih dalam dan kompleks tanpa peningkatan jumlah parameter yang signifikan.

Penelitian berikutnya Kombinasi FCM-SVM dapat meningkatkan akurasi pada proses segmentasi dengan karakteristik penyakit daun tebu dengan pencahayaan yang tak seimbang akibat pengambilan secara outdoor. (Mentari, dkk, 2015), Kombinasi FCM-SVM dapat meningkatkan akurasi pada proses segmentasi dengan karakteristik penyakit daun tebu dengan pencahayaan yang tak seimbang akibat pengambilan secara outdoor. Segmentasi citra daun tebu berpenyakit memiliki beberapa tahapan yaitu praproses, pemilihan region of interest (ROI), ekstraksi fitur, dan segmentasi. Tahap praproses melakukan pengambilan bagian tulang daun serta penghapusan bagian tulang daun, kemudian pemilihan ROI menunjukan dominasi area penyakit pada daun menggunakan overlapping window seluas 100x100 pixel. Metode kombinasi FCM dan SVM digunakan untuk segmentasi daun tebu berpenyakit, dimana FCM digunakan untuk segmentasi daun tebu pada data training. Hasil segmentasi tersebut digunakan sebagai label data pada tahap kedua bersama dengan data testing menggunakan metode klasifikasi SVM. Metode segmentasi yang diusulkan mampu menunjukkan rata rata akurasi yang tinggi pada 30 citra daun tebu

berpenyakit, yaitu sebesar 76%. Sistem yang dibangun selanjutnya digunakan pada deteksi penyakit sebagai referensi untuk ketepatan permasalahan pertanian yang membutuhkan sistem deteksi penyakit sejak dini. Namun akurasi di penelitian yang menggunakan Metode segmentasi yang diusulkan mampu menunjukkan rata-rata akurasi yang tinggi pada 30 citra daun tebu berpenyakit dapat di tingkatkan lagi dari angka 76%.

Pada penelitian (Ratnasari, dkk, 2017) Penelitian ini mengusulkan diagnosis penyakit bercak tebu menggunakan metode image processing berdasarkan fitur tekstur Gray Level Coarseness Texture (SGLCM) berbasis segmentasi dan momen warna. Metode yang diusulkan terdiri dari mengekstraksi fitur warna dari citra input, yang menghasilkan 12 fitur warna, dan mengekstraksi fitur tekstur dari citra input tersegmentasi, dan menghasilkan 24 fitur tekstur, kemudian gabungan fitur warna dan permukaan diambil sebagai input k-Nearest Neighbor (kNN) untuk mengidentifikasi jenis cemar pada citra daun tebu. Jenis cacat terdiri dari cincin, karat dan bercak kuning dengan karakteristik yang berbeda-beda. Klasifikasi busuk tebu dengan menggunakan metode ini dapat mencapai akurasi maksimal 93 persen.

Dalam penelitian (Hassan, dkk, 2021), Mengganti Model yang diimplementasikan dilatih dengan data terbuka yang terdiri dari 14 spesies tanaman berbeda dan 38 kategori penyakit dan daun tanaman sehat yang berbeda. Berbagai parameter seperti set yang berbeda, break dan jumlah epoch digabungkan untuk mengevaluasi kinerja model. Model yang diimplementasikan mencapai akurasi klasifikasi penyakit masing-masing 98,42%, 99,11%, 97,02%,

dan 99,56% dengan InceptionV3, InceptionResNetV2, MobileNetV2, dan EfficientNetB0, yang lebih besar daripada Pendekatan berbasis fitur buatan tangan tradisional. Dibandingkan dengan model pembelajaran mendalam lainnya, model yang diimplementasikan mencapai akurasi yang lebih baik dan membutuhkan waktu pelatihan yang lebih sedikit. Selain itu, arsitektur MobileNetV2 kompatibel dengan perangkat seluler dengan parameter yang dioptimalkan. Keakuratan hasil deteksi penyakit menunjukkan bahwa model deep CNN menjanjikan dan dapat memberikan kontribusi yang besar untuk deteksi penyakit yang efektif dan dapat memiliki potensi deteksi penyakit dalam sistem pertanian real-time.

Jamur *Fusarium moniliforme* salah satu jenis penyakit lokal tanaman tebu. Penyakit ini dapat menurunkan hasil 0,35 sampai 0,85% dari setiap persentase serangan 1%. Penyakit pokahbung dilaporkan dapat menyebabkan hilangnya hasil 10-38 % pada varietas POJ 2878. Penyakit pokahbung meningkat setelah terjadinya hujan besar atau musim hujan. Tetapi, penyakit tersebut saat ini terlihat sepanjang musim pertumbuhan selama periode basah dan kering (ditjenbun.pertanian.go.id).

Indonesia adalah negara agraris dengan perekonomian yang sangat bergantung pada sektor perkebunan, termasuk tebu sebagai komoditas utama dalam produksi gula. Namun, produktivitas tebu sering terganggu oleh penyakit seperti *yellow disease*, *redrot*, *mosaic*, dan *rust*, yang menyebabkan penurunan hasil panen. Deteksi penyakit ini perlu dilakukan segera karena berdampak signifikan terhadap kualitas dan kuantitas tebu yang dihasilkan. Sayangnya, proses identifikasi manual memiliki kelemahan, seperti rentan terhadap kesalahan

manusia dan kurang efisien, terutama pada perkebunan berskala besar. Terdapat beberapa penelitian terdahulu yang membahas penyakit tebu berdasarkan munculnya bercak suatu penyakit pada daun tebu, seperti penelitian [1] penelitian yang dilakukan tidak membahas segmentasi berbasis wilayah atau metode pemerataan histogram adaptif yang ditingkatkan. Sebagai gantinya, penelitian ini menyoroti arsitektur deep learning bertingkat dengan mekanisme perhatian untuk mengklasifikasikan penyakit daun tebu, mencapai akurasi 86,53% pada dataset yang dikembangkan secara mandiri.

Dalam penelitian [2] membahas segmentasi berbasis wilayah atau model pemerataan histogram adaptif yang ditingkatkan untuk klasifikasi penyakit daun tebu. Ini berfokus pada analisis prediktif berbasis CNN dan SVM untuk mengklasifikasikan tujuh jenis penyakit daun dengan akurasi tinggi. Segmentasi berbasis wilayah atau model pemerataan histogram adaptif yang ditingkatkan untuk klasifikasi penyakit daun tebu. Ini berfokus pada model pembelajaran mendalam seperti ResNet-50 dan VGG-16 untuk mengklasifikasikan penyakit berdasarkan kumpulan data gambar seperti pada penelitian [3], [4], [5] dan [6]. Hasil yang diperoleh dengan segmentasi berbasis wilayah atau model pemerataan histogram adaptif yang ditingkatkan. Ini berfokus pada pendekatan pembelajaran mendalam untuk mengklasifikasikan daun tebu yang sehat dan sakit, mencapai akurasi 97% menggunakan 1200 gambar. Pendekatan Convolutional Neural Network (CNN) untuk deteksi penyakit, mencapai akurasi 95,2% pada kumpulan data gambar daun tebu [7], [8], [9].

Dalam penelitian [10], model yang menggunakan teknik CNN dan SVM untuk membuat prediksi yang tepat tentang tingkat keparahan Penyakit pucuk rumput dalam budidaya tebu diperkenalkan, dan akurasi keseluruhannya adalah 81,53%, dan presisi, ingatan, skor F1, dan nilai dukungan berkisar dari 65,71% hingga 85,37% tergantung pada tingkat keparahannya. Penelitian yang dilakukan oleh [11], [12], [13], [14], [15] memberikan bukti bahwa model pembelajaran mendalam dapat berkinerja lebih baik dalam masalah klasifikasi dan menyarankan beberapa perbaikan untuk melanjutkan kontribusinya. Demikian juga pada penelitian [16] jaringan saraf dalam diusulkan untuk identifikasi otomatis penyakit tebu, yang melibatkan 5 jenis penyakit dan 1 kelas sehat, dan analisis komparatif untuk pengoptimal yang berbeda penurunan gradien stokastik, Adadelta dan Adam diberikan.

Penelitian yang dilakukan oleh [17] memperkenalkan Sistem Prediksi Penyakit Tebu berbasis AI menggunakan *Convolutional Neural Network* (CNN) untuk mengklasifikasikan gambar tebu ke dalam kategori Bakteri Hawar, Sehat, atau Red Rot, membantu petani dan peneliti dalam deteksi dini penyakit melalui aplikasi web yang ramah pengguna. Dalam penelitian [18] berdasarkan hasil pengujian, klasifikasi terbaik adalah AlexNet dan *Support Vector Machine* dengan akurasi, sensitivitas, spesifisitas masing-masing 93,5%, 95,08%, dan 93%. Demikian juga pada penelitian [2], [19], [20] dan [21].

Dari penelitian-penelitian sebelumnya dapat dilihat berbagai metode CNN dan SVM telah dilakukan namun memiliki kelemahan pada akurasi, untuk itu

menjadi penting dalam penelitian ini dilakukan peningkatan akurasi untuk identifikasi penyakit daun padi dengan menggunakan VGG-16.

Dari beberapa paper diulas di atas masih membahas, masih terdapat peluang penelitian untuk deteksi penyakit tanaman tebu berdasarkan citra daun, Convolutional Neural Network (CNN) sebagai contoh dengan membandingkan beberapa arsitektur yang berbeda dan bereksperimen dengan kumpulan data yang berbeda. Oleh karena itu, peneliti melakukan analisis dan kajian dengan judul “Deteksi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network”. Penelitian ini bertujuan untuk mengetahui tingkat akurasi model yang diperoleh dan bagaimana model CNN dapat mengklasifikasikan citra penyakit daun tebu dengan lebih baik dan akurat.

## **1.2. Rumusan Masalah**

Berdasarkan latar belakang yang telah disampaikan sebelumnya, maka rumusan permasalahan pada penelitian ini adalah sebagai berikut : Apa metode yang tepat untuk mengidentifikasi penyakit pada daun tebu?

### 1.3. Batasan Masalah

Batasan masalah pada penelitian ini antara lain adalah :

- a. Metode yang digunakan untuk klasifikasi citra adalah *Convolutional Neural Network (CNN)*.
- b. Dataset yang digunakan untuk penelitian ini bersifat publik yang didapatkan dari website [www.kaggle.com](http://www.kaggle.com).
- c. Platform penelitian menggunakan Google Colaboratory.
- d. Target penelitian hanya modeling akurasi uji dengan python tidak sampai implementasi pembuatan aplikasi enduser.

### 1.4. Tujuan Penelitian

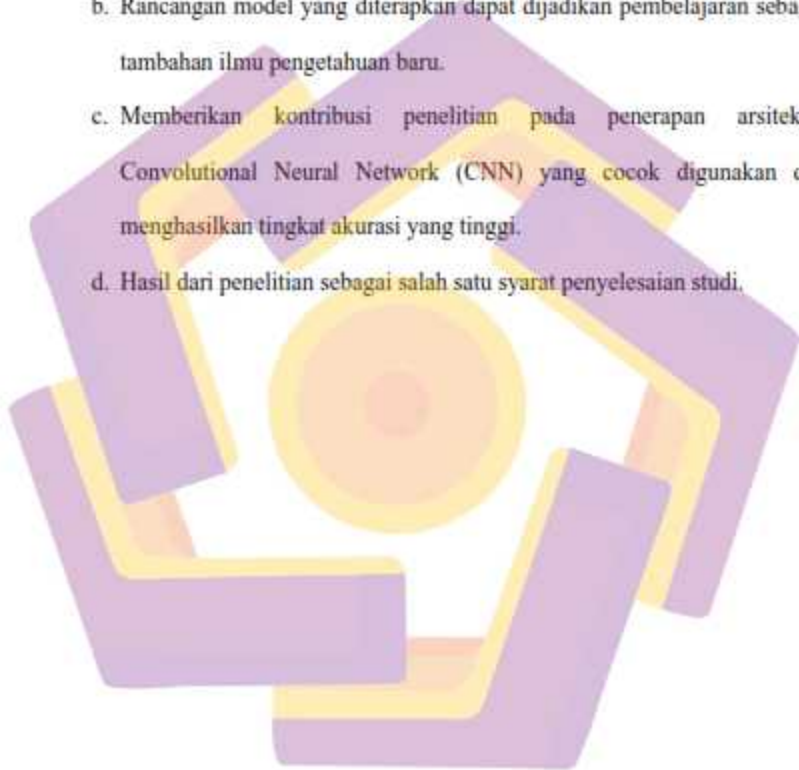
Penelitian ini bertujuan untuk mencapai beberapa hal berikut:

- a. Mengetahui bagaimana implementasi CNN menggunakan metode VGG 16 untuk mendeteksi penyakit pada tanaman Tebu.
- b. Mencari rancangan arsitektur model klasifikasi dengan nilai akurasi yang terbaik pada identifikasi penyakit daun tanaman Tebu menggunakan Convolutional Neural Network (CNN).
- c. Model dapat digunakan sebagai bahan penelitian lanjutan yang harapannya dapat membantu para petani dalam mengendalikan penyakit pada daun tanaman Tebu secara tepat dan akurat.

### 1.5. Manfaat Penelitian

Penelitian ini dimaksudkan untuk memberikan manfaat sebagai berikut:

- a. Hasil rancangan model klasifikasi dapat digunakan untuk mempercepat penanganan dalam mengidentifikasi penyakit daun tanaman Tebu.
- b. Rancangan model yang diterapkan dapat dijadikan pembelajaran sebagai tambahan ilmu pengetahuan baru.
- c. Memberikan kontribusi penelitian pada penerapan arsitektur Convolutional Neural Network (CNN) yang cocok digunakan dan menghasilkan tingkat akurasi yang tinggi.
- d. Hasil dari penelitian sebagai salah satu syarat penyelesaian studi.



## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Tinjauan Pustaka

Sebelum melaksanakan penelitian terkait identifikasi penyakit tanaman tebu berdasarkan citra daun, peneliti terlebih dahulu melakukan peninjauan pustaka yang artinya ringkasan penelitian sebelumnya tentang topik tertentu. bagian ini biasanya terdapat pada bab kedua karya ilmiah.

Penelitian dilakukan oleh (Dewi, dkk), tentang penyakit Karat dan mosaik, penyakit I I sangat merugikan petani tebu dikarenakan pertumbuhan tanaman tebu menyusut dan tidak dapat berkembang dengan baik. Deteksi penyakit tebu sangatlah membantu untuk peningkatan produksi tebu dan menghasilkan panen yang optimal. Penelitian yang dilakukan (Dewi, dkk), membangun sistem identifikasi penyakit pada daun tebu melalui identifikasi citra digital daun dengan pemilihan fitur tekstur dan warna melalui *gray level co-occurrence matrix* (GLCM) dan *color moments*. Penelitian ini menggunakan metode klasifikasi *support vector machine* (SVM). Pengujian dilakukan untuk mengetahui fitur yang kemunculannya menyebabkan perubahan dalam hasil klasifikasi dengan 4 skenario. Skenario 4 merupakan kombinasi fitur yang direkomendasikan untuk identifikasi penyakit pada daun tebu dengan akurasi 97%. Untuk lebih lanjut peneliti berikutnya (Ratnasari, dkk.) Juga melakukan penelitian penyakit yang menyerang tebu dapat disebabkan oleh bakteri, jamur maupun virus. Penyakit yang bernama noda yang terdapat di tebu, membuat tebu menimbulkan bercak dan

mempengaruhi pad produksi gulanya. Penelitian Ini mengusulkan pengenalan penyakit noda tanaman tebu yang terdiri dari noda cincin, noda karat, dan noda kuning berdasarkan fitur tekstur yang merupakan kombinasi dari konsep Gray Level Co-Occurrence Matrix (GLCM) Dan dimensi fractal yang dinamakan Fractal Dimension Co-Occurrence Matrix (FDCM). Pengenalan penyakit noda pada tanaman tebu menggunakan metode tersebut dapat menghasilkan akurasi tertinggi 90%.

Penelitian selanjutnya oleh (Mentari, dkk). Penyakit pada tanaman tebu harus segera di obati atau dihilangkan, dikarenakan mempengaruhi hasil yang kurang maksimal pada waktu tebu di panen. Deteksi penyakit yang secara manual dilakukan oleh ahli membutuhkan waktu dan biaya yang tinggi. Penelitian ini bertujuan untuk membangun sistem yang secara otomatis mampu melakukan segmentasi citra daun tebu berpenyakit menggunakan Fuzzy C Means (FCM)-Support Vector Machine (SVM) dengan fitur warna  $a^*$ . Tahap praproses melakukan pengambilan bagian tulang daun serta penghapusan bagian tulang daun, kemudian pemilihan ROI menunjukan dominasi area penyakit pada daun menggunakan overlapping window seluas  $100 \times 100$  pixel. Metode segmentasi yang diusulkan mampu menunjukkan rata rata akurasi yang tinggi pada 30 citra daun tebu berpenyakit, yaitu sebesar 76%. (Irfansyah, dkk, 2021). Juga meneliti, tentang penyakit pada kopi. Banyak faktor yang membuat hal ini terus berlanjut, diantaranya adalah banyak pohon kopi petani yang terserang penyakit. Pada penelitian ini penulis mengimplementasikan arsitektur *Convolutional Neural Network* (CNN) Alexnet dengan platform pemrograman MATLAB untuk

identifikasi penyakit pada tanaman kopi melalui citra. Jumlah total *dataset* yang digunakan sebanyak 300 data yang terbagi dalam 3 kelas yaitu *health*, *rust* dan *red spider mite*. Proses *training* yang melibatkan 260 data latih menghasilkan akurasi dengan nilai 69.44-80.56%. Proses pengujian jaringan menggunakan 40 data uji menghasilkan akurasi sebesar 81.6%. Berdasarkan hasil penelitian dapat dikatakan bahwa arsitektur Alexnet akurat untuk klasifikasi hama daun pada tanaman kopi.



## 2.2. Keaslian Penelitian

Tabel 2.2.1. Matriks Literatur Review dan Posisi Penelitian  
Deteksi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan  
Metode Convolutional Neural Network

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Sugarcane leaf polysaccharide exerts a therapeutic effect on cardiovascular diseases through necroptosis	Kaili Sun, Renyikun Yuan, Jia He, Youqiong Zhuo, Ming Yang, Erwei Hao, Xiaotao Hou, Chun Yao, Shilin Yang, Hongwei Gao, Media Publikasi Heliyon, Tahun 2023.	Tujuan penelitian ini adalah untuk menyelidiki efek perlindungan dari polisakarida daun tebu ( <i>Sugarcane Leaf Polysaccharide</i> atau SLP) terhadap cedera <i>myocardial ischemia-reperfusion</i> (MI/R) serta mekanisme yang mendasarinya, baik dalam kondisi <i>in vitro</i> (sel H9c2 yang dirangsang TBHP) maupun <i>in vivo</i> (pada tikus Sprague Dawley). Penelitian ini bertujuan memahami bagaimana SLP dapat memitigasi kerusakan seluler melalui penghambatan <i>necroptosis</i> dan stres oksidatif, serta melalui	Kesimpulan penelitian ini adalah bahwa polisakarida daun tebu (SLP) terbukti mampu mengurangi stres oksidatif dan <i>necroptosis</i> melalui modulasi jalur sinyal Nrf2/HO-1 dan RIP1/RIP3/MLKL, baik dalam eksperimen <i>in vitro</i> maupun <i>in vivo</i> . Dalam studi <i>in vitro</i> , SLP mampu mengurangi <i>necroptosis</i> , kehilangan potensi membran mitokondria (MMP), produksi ROS, dan stres	<ul style="list-style-type: none"> <li>□ <b>Keterbatasan Model In Vitro:</b> Sel H9c2 yang digunakan dalam eksperimen <i>in vitro</i> tidak sepenuhnya mencerminkan kondisi <i>in vivo</i>, sehingga hasilnya mungkin tidak secara sempurna merepresentasikan keadaan biologis yang lebih kompleks pada hewan atau manusia.</li> <li>□ <b>Keterbatasan Perlakuan SLP pada Model Hewan:</b> Penelitian ini hanya menggunakan</li> </ul>	Dalam penelitian ini, polisakarida daun tebu (SLP) ditunjukkan memiliki efek perlindungan terhadap cedera <i>myocardial ischemia-reperfusion</i> (MI/R) melalui penghambatan <i>necroptosis</i> dan pengurangan stres oksidatif. Ketika dibandingkan dengan penelitian lain yang juga mengeksplorasi perlindungan terhadap MI/R,

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			<p>aktivasi jalur sinyal Nrf2/HO-1</p>	<p>oksidatif yang dirangsang oleh TBHP. Pada percobaan <i>in vivo</i>, SLP memperbaiki kerusakan akibat cedera <i>myocardial ischemia-reperfusion</i> (MI/R) dengan mengurangi stres oksidatif dan <i>necroptosis</i>. Temuan ini menunjukkan bahwa SLP berpotensi dikembangkan sebagai obat baru untuk perlindungan kardiovaskular, khususnya dalam mengatasi cedera MI/R melalui pengurangan stres oksidatif dan <i>necroptosis</i></p>	<p>model hewan dengan perlakuan SLP secara preventif sebelum induksi cedera MI/R. Penggunaan SLP setelah terjadinya cedera mungkin akan memberikan hasil yang berbeda dan perlu diteliti lebih lanjut.</p> <p><b>Perlu Penelitian Klinis:</b> Meskipun SLP menunjukkan potensi perlindungan kardiovaskular, hasil pada hewan percobaan mungkin tidak sepenuhnya berlaku pada manusia. Oleh karena itu, diperlukan penelitian lebih lanjut, termasuk uji klinis, untuk</p>	

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					<p>memastikan efektivitas dan keamanan SLP pada manusia.</p> <p>□ <b>Mekanisme</b></p> <p><b>Tambahan:</b> Walaupun penelitian ini telah mengeksplorasi jalur sinyal Nr2/HO-1 dan RIP1/RIP3/MLKL, kemungkinan adanya jalur lain yang berperan dalam efek perlindungan SLP terhadap cedera MIR juga layak untuk diteliti lebih mendalam di masa depan</p>	
2	Digital evolution and twin miracle of sugarcane breeding	Xiaoding Wang, Qibin Wu, Haitao Zeng, Xu Yang, Xuechao Yang, Xun Yi, Ibrahim Khalil, Youxiong Que, Media Publikasi Field Crops Research, Tahun 2024	Tujuan penelitian ini adalah untuk mengembangkan sistem pembiakan tebu cerdas berbasis teknologi kecerdasan buatan (AI).	Kesimpulan dari penelitian ini adalah bahwa sistem pembiakan tebu cerdas yang diusulkan, yang menggabungkan	Ada banyak metode yang dikembangkan dalam deteksi dan klasifikasi penyakit tanaman menggunakan	(Hassan, dkk) dan penulis sama-sama menggunakan CNN, untuk perbedaan dan perbandingan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			<p><i>blockchain</i>, dan <i>digital twin</i>. Penelitian ini bertujuan untuk meningkatkan efisiensi, keamanan, dan ketepatan dalam proses pembiakan tebu dengan menggunakan pendekatan <i>Human-Cyber-Physical System (H-CPS)</i>. Dengan memadukan data genetik dan fenotipik tebu, sistem ini bertujuan untuk mempercepat siklus pembiakan, meningkatkan efisiensi perbaikan sifat genetik, dan memastikan ketelusuran serta integritas data pembiakan melalui teknologi <i>blockchain</i>.</p>	<p>kecerdasan buatan (AI), <i>blockchain</i>, dan <i>digital twin</i> dalam kerangka <i>Human-Cyber-Physical System (H-CPS)</i>, dapat secara signifikan meningkatkan efisiensi, keamanan, dan ketepatan dalam proses pembiakan tebu. Sistem ini mampu memperpendek siklus pembiakan, meningkatkan efisiensi seleksi varietas unggul, dan memberikan keputusan yang lebih tepat dan dapat diandalkan dalam pemilihan tanaman tebu.</p> <p>Teknologi <i>blockchain</i> memastikan keamanan dan ketelusuran data</p>	<p>daun tanaman yang sakit. Namun, masih belum ada komersial yang efisien dan efektif digunakan untuk mengidentifikasi penyakit. Dibandingkan dengan pembelajaran mendalam lainnya pendekatan, model pembelajaran mendalam yang diterapkan memiliki kemampuan prediksi yang lebih baik dalam hal baik akurasi maupun kerugian. Waktu yang dibutuhkan untuk melatih model jauh lebih sedikit daripada pendekatan pembelajaran</p>	<p>disini Cuma pada model yang dipakai penulis dan juga (Hassan, dkk), untuk (Hassan, dkk) menggunakan model <i>deep convolutional-neural-network</i></p>

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				<p>pembukaan, sementara digital twin memungkinkan simulasi real-time untuk memantau kondisi pertumbuhan dan lingkungan tanaman. Dengan pendekatan ini, pembukaan tebu menjadi lebih efisien, aman, dan berkelanjutan, mengatasi keterbatasan metode pembukaan tradisional yang memiliki siklus panjang dan kompleksitas tinggi.</p>	mesin lainnya.	
3	<p><i>Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun</i></p>	<p>Irfansyah, D., Mustikasari, M., Suroso, A Sistem Informasi Bisnis, J., Ilmu Komputer dan Teknologi Informasi, F., Gunadarma, U., Sistem Informasi, J., Bani Saleh, S., Margonda Raya No, J., Depok, B., &amp; Hasibuan No, J. M. (2021). 6(2). <a href="https://data.mendeley.com/datasets/c5yvn32drg/2">https://data.mendeley.com/datasets/c5yvn32drg/2</a>.</p>	<p>Pada penelitian ini penulis mengimplementasikan arsitektur <i>Convolutional Neural Network (CNN) Alexnet</i> dengan platform pemrograman MATLAB untuk</p>	<p>Berdasarkan penelitian yang dilakukan dapat disimpulkan arsitektur CNN Alexnet dapat diimplementasikan dengan platform pemrograman</p>	<p>Klasifikasi hama pada penelitian ini fokus pada daun tanaman kopi, kedepan dapat dikembangkan klasifikasi hama melalui bagian lain tanaman kopi</p>	<p>Penelitian (Irfansyah, dkk) dan penulis dalam penelitian disini menggunakan algoritma sama, menggunakan arsitektur sama</p>

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	<i>Tanaman Kopi</i>		identifikasi penyakit pada tanaman kopi melalui citra. Berdasarkan hasil penelitian dapat dikatakan bahwa arsitektur Alexnet akurat untuk klasifikasi hama daun pada tanaman kopi.	MATLAB. Nilai akurasi klasifikasi jaringan terhadap data <i>testing</i> mencapai 0.816 sehingga dapat disimpulkan arsitektur CNN Alexnet akurat untuk klasifikasi hama pada daun tanaman kopi	misalnya batang, akar dan buah.	yang membedakan adalah objectnya
4	<i>Segmentasi Penyakit pada Citra Daun Tebu Menggunakan Fuzzy C Means-Support Vector Machine dengan Fitur Warna a</i>	Mentari, M., Gimardi, R. V. H., Fatichah, C.	Deteksi penyakit yang secara manual dilakukan oleh ahli membutuhkan waktu dan biaya yang tinggi. Oleh karena itu, diperlukan otomatisasi sistem untuk mendeteksi penyakit pada tanaman tebu. Penelitian ini bertujuan untuk membangun sistem yang secara otomatis mampu melakukan segmentasi citra daun tebu berpenyakit	Penggunaan fitur warna <i>channel a</i> dari <i>colorspace L*a*b*</i> membantu metode yang ada pada skenario penelitian ini melakukan segmentasi dengan baik dibandingkan dengan <i>channel RGB, B, atau I</i> . Penggunaan dua metode dalam segmentasi, yaitu metode klustering	Metode segmentasi FCM-SVM mampu mensegmentasi citra daun tebu berpenyakit dengan akurasi tertinggi pada sebagian besar data uji coba (15 citra pada total 30 citra). Segmentasi penyakit pada citra daun tebu	Penelitian (Mentari, dkk) dan penulis dalam penelitian disini yang membedakan adalah metode yang dipakai. (Mentari, dkk) menggunakan <i>Fuzzy C Means</i>

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			menggunakan Fuzzy C Means (FCM)-Support Vector Machine (SVM) dengan fitur warna a*. Kombinasi FCM-SVM dapat meningkatkan akurasi pada proses segmentasi dengan karakteristik penyakit daun tebu dengan pencahayaan yang tak seimbang akibat pengambilan secara outdoor.	FCM dan metode klasifikasi SVM mampu melakukan segmentasi pada citra daun tebu berpenyakit dengan akurasi rata-rata 76%.	menggunakan metode FCM-SVM mampu mengatasi terutama untuk jenis penyakit yang mempunyai proyeksi warna kekuningan atau kecoklatan di sekitar daerah penyakit.	
5	<i>Pengenalan penyakit noda pada citra daun tebu berdasarkan ciri tekstur fractal dimension co-occurrence matrix dan l*a*b* color moments.</i>	Ratnasari, E. K., Ginardi, R. V. H., Fatichah, C., Teknologi, I., & Nopember, S. (n.d.).	Penelitian ini mengusulkan pengenalan penyakit noda tanaman Tebu yang terdiri dari noda cincin, noda karat, dan noda kuning berdasarkan fitur tekstur yang merupakan kombinasi dari konsep Gray Level Co-Occurrence Matrix (GLCM) Dan dimensi fractal yang dinamakan Fractal Dimension Co-	Berdasarkan evaluasi uji coba yang telah dilakukan dapat disimpulkan bahwa kombinasi fitur tekstur FDCM [9] dan $L^*a^*b^*$ color moments dalam mengidentifikasi tiga penyakit noda pada citra daun tebu dapat	Pola lesi dari penyakit noda mempengaruhi hasil pengenalan dimana penyakit karat yang berbentuk coklat memanjang dapat dikenali sebagai noda cincin karena penyakit noda cincin pada awal gejala berbentuk	Penelitian (Ratnasari, dkk) dan penulis dalam penelitian disini yang membedakan adalah konsep dan juga metode yang dipakai. (Ratnasari, dkk) kombinasi dari konsep Gray Level Co-Occurrence Matrix (GLCM)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			<p>Occurrence Matrix (FDCM). Sedangkan fitur warna didapatkan dari perhitungan statistik color moments pada citra <math>L^*a^*b^*</math>. Kombinasi fitur tersebut menghasilkan 12 fitur warna dan 6 fitur tekstur yang kemudian digunakan sebagai masukan klasifikasi k-Nearest Neighbor (KNN).</p>	<p>menunjukkan performa lebih baik dengan akurasi sebesar 90% dibandingkan dengan kombinasi fitur tekstur GLCM dan <math>L^*a^*b^*</math> color moments yang menunjukkan akurasi sebesar 83%. Metode tersebut dapat mengenali dengan baik jenis penyakit noda cincin dan kuning dengan akurasi 100%, sedangkan akurasi menurun menjadi 66% ketika mengenali citra daun berlesi noda kuning dan 88% pada citra non-noda.</p>	<p>coklat memanjang yang kemudian melebar dan bagian tengah lesi biasanya menjadi kekuning-kuningan dan tepi akan terlihat jelas berwarna merah kecoklatan. Selain itu, pemilihan area non-noda yang masih mengandung bercak yang bukan merupakan lesi suatu penyakit noda menyebabkan kesalahan klasifikasi. Oleh karena itu sebaiknya pada</p>	<p>Dan dimensi fractal</p>


No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					saat memilih data berupa kelas non-noda berupa bagian daun yang normal, yaitu berwarna hijau dan tidak memiliki bercak.	
6	Klasifikasi penyakit noda pada citra daun tebu berdasarkan ciri tekstur dan warna menggunakan segmentation-based gray level cooccurrence matrix dan lab color moments.	Ratnasari, E. K., Gimardi, R. V. H., & Faticah, C. (2017). <i>Register: Jurnal Ilmiah Teknologi Sistem Informasi</i> , 3(1), 1–10. <a href="https://doi.org/10.26594/register.v3i1.575">https://doi.org/10.26594/register.v3i1.575</a>	Oleh karena itu, dalam meningkatkan kualitas produksi gula dibutuhkan diagnosa dini untuk mengambil keputusan penanganan penyakit yang cepat dan tepat, sehingga dapat meminimalisir kerusakan daun yang signifikan akibat penyebaran penyakit tersebut. Penelitian ini mengusulkan diagnosa penyakit noda tanaman tebu menggunakan metode pemrosesan citra berdasarkan fitur tekstur <i>Segmentationbased Gray Level Co-</i>	Berdasarkan evaluasi uji coba yang telah dilakukan, dapat disimpulkan bahwa metode yang diajukan dalam mengidentifikasi tiga penyakit noda pada citra daun tebu dapat menunjukkan performa paling baik dengan akurasi tertinggi sebesar 93% dibandingkan dengan kombinasi fitur lainnya yang telah dilakukan pada percobaan. Informasi warna dan tekstur berpengaruh	Selain itu segmentasi yang baik diperlukan untuk mendapat informasi yang akurat dari lesi suatu penyakit noda. Segmentasi tersebut berpengaruh pada pengenalan citra, di mana terkadang terdapat bercak yang bukan merupakan lesi penyakit noda sehingga dapat menimbulkan kesalahan klasifikasi yang tidak sesuai	Penelitian (Ratnasari, dkk) dan penulis dalam penelitian disini yang membedakan adalah konsep dan juga metode yang dipakai. (Ratnasari, dkk) kombinasi dari konsep ciri tekstur menggunakan segmentation-based gray level cooccurrence matrix dan lab color moments.

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			<p><i>Occurrence Texture (SGLCM) dan LAB color moments</i>. Metode yang diajukan terdiri dari ekstraksi ciri warna pada citra masukan yang akan menghasilkan 12 fitur warna dan ekstraksi ciri tekstur pada citra masukan yang tersegmentasi dan menghasilkan 24 fitur tekstur, kemudian gabungan fitur warna dan tekstur tersebut digunakan sebagai masukan klasifikasi <i>k-Nearest Neighbor</i> (kNN) untuk mengenali jenis penyakit noda pada citra daun tanaman tebu.</p>	<p>terhadap pengenalan jenis penyakit noda pada citra daun tebu, di mana terdapat kesalahan klasifikasi yang memiliki tekstur maupun warna yang mirip.</p>	<p>dengan label <i>ground truth</i>.</p>	

## 2.3 Landasan Teori

### 2.3.1 Pengertian Citra

Citra adalah gambar pada bidang dua dimensi yang dihasilkan dari gambar analog dua dimensi dan kontinu menjadi gambar diskrit, melalui proses sampling gambar analog dibagi menjadi  $M$  baris dan  $N$  kolom sehingga menjadi gambar diskrit (Purba, 2010). Gambar 1 adalah koordinat citra digital terhadap sumbu  $(x,y)$  suatu bidang dua dimensi.



**Gambar 2.1.** Koordinat citra digital

Citra digital secara matematis dapat ditulis dalam bentuk matriks sebagai berikut:

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix}$$

**Gambar 2.2.** Matriks citra digital

### 2.3.2 Pengolahan Citra Digital

Pengolahan citra digital atau bisa juga disebut image processing adalah proses pengolahan pada suatu citra hasil keluaran berupa citra juga (Nafi'iyah & Mujilahwati, 2018). Awal mula dari pengolahan citra adalah perbaikan untuk citra, kemudian dengan perkembangan zaman dibarengi dengan perkembangan dunia komputer maka image processing semakin berkembang dan banyak digunakan untuk berbagai kebutuhan. Seiring perkembangannya, pengolahan citra memiliki tujuan utama sebagai berikut :

- a. Perbaikan kualitas yang dimiliki citra, dimana keluaran dari hasil pengolahan citra ini adalah dapat menampilkan informasi pada citra secara lebih jelas.
- b. Ekstraksi ciri dari suatu citra, yaitu hasil keluaran dari proses pengolahan ini adalah berupa informasi citra dimana manusia mendapatkan informasi ciri dari citra secara numerik, atau dengan kata lain komputer melakukan interpretasi terhadap informasi yang ada pada citra melalui besaran numerik data yang dibedakan secara jelas.


### 2.3.3 Klasifikasi

Klasifikasi banyak digunakan dalam berbagai hal, diantaranya untuk deteksi kecurangan, pengolahan pelanggan, deteksi kematangan buah, identifikasi penyakit dan masih banyak lainnya. Klasifikasi sendiri memiliki pengertian yaitu suatu teknik yang digunakan untuk mempelajari sekumpulan data yang mana menghasilkan suatu aturan dan ketentuan tertentu yang bisa digunakan untuk mengenali data-data yang baru dan belum pernah ditemui sebelumnya (Suyanto, 2017). Klasifikasi dalam

*machine learning* dikategorikan ke dalam *supervised learning*, atau pembelajaran yang diawasi. *Supervised learning* memiliki artian bahwa data yang digunakan sudah dikelompokkan pada kelas-kelas yang sudah diberi label.

### 2.3.4 Convolutional Neural Network

*Convolutional Neural Network* atau disingkat CNN suatu pengembangan dari Multilayer Perceptron (MLP) yang dapat digunakan untuk mengolah data citra khususnya gambar dua dimensi. *Convolutional Neural Network* (CNN) sering digunakan untuk mengenali benda atau mendeteksi suatu objek (Arrofiqoh & Harintaka, 2018). *Convolutional Neural Network* merupakan bagian dari *deep neural network* yang umumnya digunakan untuk pengenalan dan pemrosesan gambar karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Pada arsitektur *Convolutional Neural Network* (CNN) dapat menangkap informasi kontekstual yang terkadang di dalam data seperti pixel yang saling berdekatan pada sebuah citra, yang berarti model CNN dapat melakukan ekstraksi ciri pada sebuah citra secara mandiri.



**Gambar 2.3.** Arsitektur Arsitektur Convolutional Neural Network

Sebuah model Convolutional Neural Network pada dasarnya terdiri dari beberapa layer untuk proses penyelesaian klasifikasi citra sebagai berikut :


a. Layer Input

Layer atau lapisan ini adalah dimana citra yang akan digunakan sebagai dataset untuk proses klasifikasi dimasukkan ke dalam model klasifikasi.

b. Layer Convolutional

Layer atau lapisan ini berfungsi untuk operasi konvolusi (convolution) terhadap sejumlah node pada citra menggunakan beberapa filter. Pada operasi ini membantu neural network (jaringan saraf) untuk mengenali objek seperti citra daun berdasarkan atribut-atributnya. Lapisan konvolusi terdiri dari susunan sedemikian rupa neuron yang membentuk sebuah filter. Pada Gambar 3 adalah contoh proses konvolusi dengan menggunakan filter 3x3, pada proses konvolusi ini piksel pada citra dikalikan dengan piksel filter dan menghasilkan keluaran yang biasa disebut feature map.

## CONVOLUTIONAL NEURAL NETWORKS (CNNs) AND LAYER TYPES



Gambar 2.4. Layer Convolution

### c. Layer ReLU

Layer ini merupakan fungsi aktivasi dari output layer sebelumnya. Pada arsitektur Convolutional Neural Network, fungsi aktivasi terletak pada perhitungan akhir keluaran feature map atau sesudah proses perhitungan konvolusi atau pooling untuk menghasilkan suatu pola fitur. Pada fungsi ReLU atau Rectified Linear Unit melakukan threshold dari 0 hingga infinity, dalam artian fungsi ini masukan dari neuron-neuron berupa bilangan negatif, maka fungsi ini akan menerjemahkan nilai tersebut ke dalam nilai 0, dan jika masukan bernilai positif maka output dari neuron adalah nilai aktivasi itu sendiri.

### d. Layer Pooling

Pooling layer merupakan lapisan yang mengurangi dimensi dari feature map. Pada proses ini digunakan untuk mengurangi resolusi gambar dengan tetap mempertahankan informasi pada gambar, sehingga akan memberikan kecepatan yang lebih dalam melakukan komputasi untuk

klasifikasi. Lapisan ini biasa diterapkan setelah lapisan konvolusi dan memiliki beberapa jenis diantaranya adalah max pooling dan average pooling. Lapisan pooling yang digunakan terdiri dari sebuah filter yang memiliki ukuran tertentu dan juga stride tertentu, dimana stride adalah jumlah pergeseran dari filter pada saat proses pooling.

e. Layer Full Connected

Lapisan ini berfungsi untuk menghitung hasil output dari layer konvolusi dan pooling. Pada lapisan konvolusi keluaran yang dihasilkan masih dalam bentuk multi-dimensional array, maka diperlukan proses bernama flatten dimana maksud flatten disini adalah mengubah keluaran hasil konvolusi (feature map) menjadi bentuk vektor.

### 2.3.5 Confusion Matrix

Confusion Matrix dapat digunakan untuk mengevaluasi klasifikasi model dalam memperkirakan objek yang benar atau salah. True positive (TP) dan true negative (TN) memberikan informasi ketika klasifikasi benar, sedangkan false positive (FP) dan false negative (FN) memberikan informasi ketika klasifikasi salah (Pravina et al., 2019).

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

**Gambar 2.5.** *Confusion Matrix*

Keterangan :

- TP (True Positive) merupakan banyaknya data yang kelas aktualnya adalah kelas positif dengan kelas prediksinya merupakan kelas positif.
- FN (False Negative) merupakan banyaknya data yang kelas aktualnya adalah kelas positif dengan kelas prediksinya merupakan kelas negatif.
- FP (False Positive) merupakan banyaknya data yang kelas aktualnya adalah kelas negatif dengan kelas prediksinya merupakan kelas positif.
- TN (True Negative) merupakan banyaknya data yang kelas aktualnya adalah kelas negatif dengan kelas prediksinya merupakan kelas negatif.

## **BAB III**

### **METODE PENELITIAN**

#### **3.1. Jenis, Sifat, dan Pendekatan Penelitian**

Jenis penelitian yang digunakan pada penelitian ini adalah eksperimental, yaitu melakukan sebuah percobaan atau skenario untuk membuktikan suatu konsep. Eksperimen yang dilakukan menggunakan beberapa rancangan arsitektur yang berbeda berdasarkan lapisan algoritma Convolutional Neural Network (CNN) untuk mencari akurasi terbaik. Dari segi sifatnya penelitian yang dilakukan adalah deskriptif yaitu membuat gambaran atau deskripsi dari percobaan yang dilakukan secara sistematis. Penelitian ini menggunakan pendekatan kuantitatif karena hasil penelitian bersifat objektif dengan skala numerik.

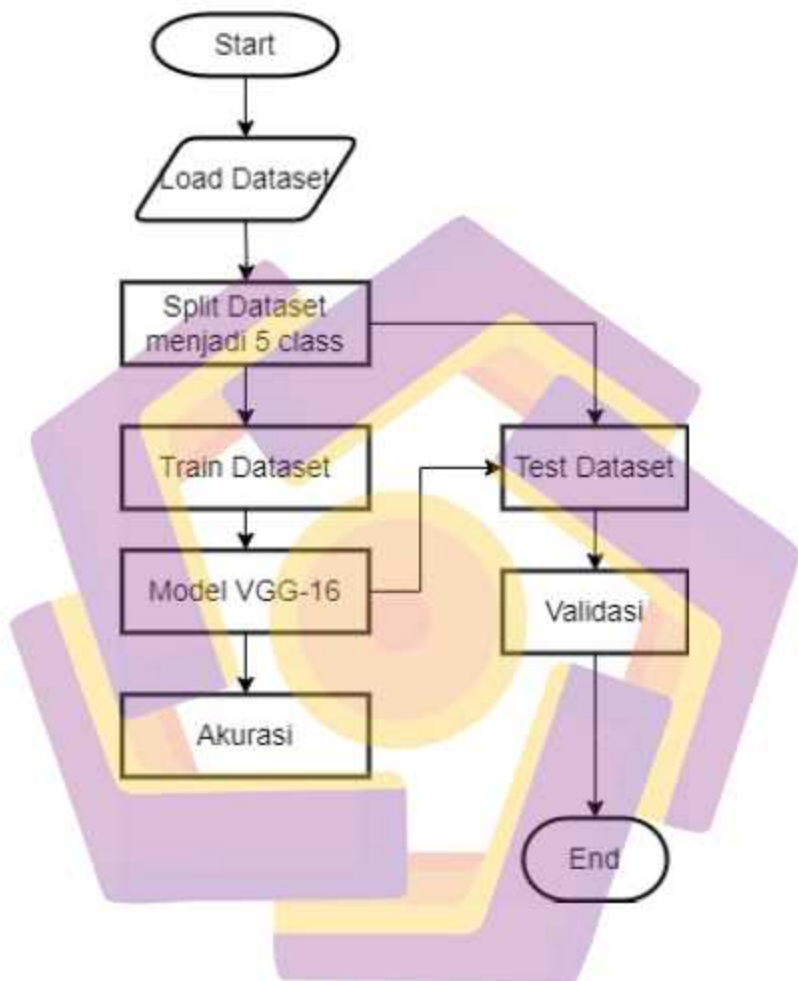
#### **3.2. Metode Pengumpulan Data**

Dataset yang digunakan dalam penelitian ini dataset public yang diambil dari Kaggle dengan link sebagai berikut: <https://www.kaggle.com/datasets/pritpal2873/sugarcane-leaf-disease-dataset>, dari dataset yang ada terdapat lima class dimana masing-masing class terdiri dari: Healthy sebanyak 522 files, Mosaic sebanyak 462 files, RedRot sebanyak 518 files, Rust sebanyak 514 files dan Yellow 505 files

### 3.3 Metode Analisis Data

Metode analisis data merupakan tahapan pengelolaan data yang digunakan pada penelitian ini untuk mendapatkan hasil yang diharapkan dari permasalahan yang telah dirumuskan. Pada penelitian ini analisis yang digunakan berupa analisis kuantitatif dengan mengolah data yang telah dikumpulkan menggunakan metode Convolutional Neural Network (CNN). Data penyakit daun tanaman Tebu yang telah dikumpulkan akan dilakukan proses preprocessing dengan augmentasi data citra sebelum digunakan proses klasifikasi daun berpenyakit di masing-masing kategori. Setelah dataset siap maka dilakukan skenario training untuk membangun model dengan arsitektur-arsitektur CNN yang telah dipilih. Pembagian data training sebesar 80%, data validation 10%, dan data testing 10%. Setelah tahap pembuatan model maka langkah selanjutnya adalah melakukan pengujian model yang telah dibangun, dimana tahap ini kita akan menguji model-model yang telah dibuat mana yang menghasilkan akurasi tertinggi. Penjelasan lebih detail dalam melakukan klasifikasi daun tanaman Tebu akan dipaparkan pada alur penelitian.

### 3.4 Alur Penelitian



**Gambar 3.1.** Alur Penelitian

### 3.5 Penjelasan Alur Penelitian

Penyelesaian penelitian dalam mengidentifikasi penyakit pada daun tanaman Tebu dilakukan dalam beberapa kegiatan yang dilakukan secara bertahap. Kerangka alur penelitian yang akan dilaksanakan, Terdapat beberapa tahapan untuk menyelesaikan penelitian tentang identifikasi penyakit pada daun tanaman Tebu. Tahapan-tahapan penelitian ini dapat dijabarkan lebih lanjut sebagai berikut :

#### 1. Start

Penelitian dimulai dengan penentuan tujuan, yaitu membangun model klasifikasi penyakit daun tebu menggunakan metode deep learning (VGG-16).

#### 2. Load Dataset

Dataset gambar daun tebu dikumpulkan dan dimuat ke dalam sistem. Dataset ini mencakup gambar daun dengan berbagai jenis penyakit maupun daun sehat.

#### 3. Split Dataset menjadi 5 class

Dataset kemudian diklasifikasikan ke dalam 5 kelas (class), yang mungkin merupakan jenis-jenis penyakit dan satu kelas untuk daun sehat. Proses ini juga mencakup pembagian dataset menjadi *training* dan *testing set*.

#### 4. Train Dataset

Data yang telah diklasifikasikan digunakan untuk melatih model. Proses pelatihan ini melibatkan penggunaan teknik augmentasi dan preprocessing data (jika dilakukan), serta penyetelan parameter model.

#### 5. Model VGG-16

Model VGG-16 digunakan sebagai arsitektur CNN untuk proses pelatihan. Model ini di-*fine-tune* menggunakan data yang telah dibagi untuk mendeteksi dan mengenali pola pada masing-masing kelas penyakit daun.

#### 6. Akurasi

Setelah pelatihan selesai, model dievaluasi menggunakan metrik akurasi untuk mengukur seberapa tepat model dapat mengenali kelas penyakit daun. Hasil akurasi ini kemudian dibandingkan dengan model sebelumnya (misalnya CNN konvensional).

#### 7. Test Dataset

Dataset yang telah disisihkan untuk pengujian digunakan untuk menguji model yang telah dilatih. Tujuannya adalah mengetahui performa model terhadap data yang belum pernah dilihat sebelumnya (*unseen data*).

#### 8. Validasi

Hasil pengujian dari *test dataset* divalidasi untuk memastikan bahwa model tidak mengalami *overfitting* dan mampu melakukan generalisasi dengan baik terhadap data baru.

#### 9. End

Penelitian berakhir setelah proses validasi selesai dan diperoleh hasil akhir berupa akurasi serta analisis performa model.

## BAB IV

### HASIL PENELITIAN DAN PEMBAHASAN

#### 4.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini dataset public yang diambil dari Kaggle dengan link sebagai berikut: <https://www.kaggle.com/datasets/pritpal2873/sugarcane-leaf-disease-dataset>, dari dataset yang ada terdapat lima class dimana masing-masing class terdiri dari: Healthy sebanyak 522 files, Mosaic sebanyak 462 files, RedRot sebanyak 518 files, Rust sebanyak 514 files dan Yellow 505 files.



Gambar 4.1 Data Set Daun Tebu

#### 4.2 Perbandingan VGG 16 dan Konvensional

Aspek	CNN Konvensional	VGG (VGG16)
Jumlah Lapisan	Biasanya 3–8 lapisan	16 atau 19 lapisan (deep network)
Struktur Layer	Kombinasi bebas: Conv + Pool + FC	Pola tetap: 2/3 Conv (3x3) + 1 MaxPool (2x2) berulang
Ukuran	Beragam (5x5, 7x7, dsb)	Selalu 3x3 dengan stride 1

Aspek	CNN Konvensional	VGG (VGG16)
Filter		
Pooling	Kadang menggunakan average pooling	Konsisten dengan max pooling (2x2)
FC Layer	Umumnya 1-2 FC layer	3 FC layer di bagian akhir

Aspek	CNN Konvensional	VGG
Jumlah Parameter	Lebih sedikit (ratusan ribu hingga jutaan)	Sangat besar ( $\pm 138$ juta parameter untuk VGG16)
Kebutuhan Komputasi	Lebih ringan	Berat, butuh GPU dengan memori besar
Latensi & Training Time	Lebih cepat	Lebih lambat karena jaringan yang dalam

Aspek	CNN Konvensional	VGG
Overfitting	Bisa terjadi pada dataset kecil	Lebih rentan jika tanpa regularisasi
PresiSI Klasifikasi	Cukup baik, tergantung desain arsitektur	Umumnya lebih tinggi dalam pengenalan objek dan klasifikasi citra
Transfer Learning	Terbatas, jarang digunakan sebagai pretrained model	Sangat populer (VGG16/VGG19 sering digunakan sebagai base model)

Aspek	CNN Konvensional	VGG
Cocok untuk	Sistem ringan, aplikasi real-time	Penelitian mendalam, klasifikasi citra kompleks
Penggunaan	Buatan sendiri atau eksperimen awal	Transfer learning, fine-tuning untuk dataset lain

## 4.2 Analisis Data

### 4.2.1 Analisis

#### a. Dataset

Dataset yang digunakan dalam penelitian ini dataset public yang diambil dari Kaggle dengan link sebagai berikut: <https://www.kaggle.com/datasets/pritpal2873/sugarcane-leaf-disease-dataset>, dari dataset yang ada terdapat lima class dimana masing-masing class terdiri dari: Healthy sebanyak 522 files, Mosaic sebanyak 462 files, RedRot sebanyak 518 files, Rust sebanyak 514 files dan Yellow 505 files, contoh gambar citra daun padi ditunjukkan pada Gambar 4.



**Gambar 4.2** Contoh citra daun padi

#### b. Split Dataset Menjadi 5 Class

Dataset yang sudah dipanggil dari Kaggle dimasukkan ke dalam data folder dan masing masing tersimpan kedalam folder sesuai dengan nama jenis penyakit daun tebu.

#### c. Bagi Dataset menjadi Data Train dan Data Test

Dataset yang sudah berada dalam folder sesuai dengan nama penyakit daun tebu, dilakukan pembagian Dataset menjadi data\_Train dan data\_Test, data dibagi kedalam 80:20. Artinya 80% data\_Train dan 20% data\_Test.

#### d. VGG-16

VGG-16, diperkenalkan oleh Simonyan dan Zisserman pada tahun 2014, merupakan salah satu arsitektur jaringan saraf konvolusional (CNN) yang populer. Model ini menggabungkan kesederhanaan desain dengan kedalaman yang signifikan, memanfaatkan tumpukan lapisan konvolusi kecil berukuran  $3 \times 3$ , diikuti oleh pooling layer untuk mengurangi dimensi spasial. Model ini terdiri dari total 16 lapisan terlatih, terdiri dari, 13 lapisan *convolutional*, 3 lapisan *fully connected (dense)*, 1 *output layer*.

Komponen utama VGG-16:

- 1) *Convolutional Layer*, Setiap lapisan menggunakan filter  $3 \times 3$  dengan padding same, sehingga dimensi output sama dengan input kecuali pada pooling.

Aktivasi ReLU

$$f(x) = \max(0, x) \quad (1)$$

digunakan untuk memperkenalkan non-linearitas

- 2) *Pooling Layer*, *Max pooling* ( $2 \times 2$ ) dengan stride 2 digunakan untuk mengurangi dimensi spasial gambar.

3) *Fully Connected Layer*, Lapisan ini menghubungkan fitur spasial dari lapisan convolutional ke lapisan output.

4) *Softmax Output*, fungsi *softmax* digunakan pada lapisan akhir untuk memberikan probabilitas untuk setiap kelas

Dimensi output untuk setiap lapisan konvolusi dapat dihitung menggunakan rumus:

$$W_{out} = \frac{W_{in} - F + 2P}{S} + 1 \quad (2)$$

$$H_{out} = \frac{H_{in} - F + 2P}{S} + 1 \quad (3)$$

Di mana:

$W_{in}, H_{in}$ : Dimensi lebar dan tinggi input

$F$ : Ukuran filter (3x3)

$P$ : Padding (biasanya 1 untuk same padding)

$S$ : Stride (biasanya 1)

$W_{out}, H_{out}$ : Dimensi lebar dan tinggi output.

Untuk pooling:

$$W_{out} = \frac{W_{in}}{S} \quad (4)$$

$$H_{out} = \frac{H_{in}}{S} \quad (5)$$

#### e. Akurasi dan Validasi

Akurasi mengukur sejauh mana prediksi model sesuai dengan label sebenarnya dalam dataset.

Rumus akurasi:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (6)$$

Di mana:

*TP (True Positive)*: Prediksi benar untuk kelas positif.

*TN (True Negative)*: Prediksi benar untuk kelas negatif.

*FP (False Positive)*: Prediksi salah untuk kelas positif.

*FN (False Negative)*: Prediksi salah untuk kelas negatif.

Validasi dilakukan untuk mengukur performa model pada data yang tidak dilibatkan dalam pelatihan (*validation set*). Biasanya, metrik seperti akurasi, *presisi*, *recall*, dan *F1-score* digunakan pada tahap validasi.

#### 1) Presisi (*Precision*)

Mengukur akurasi prediksi untuk kelas positif:

$$Presisi = \frac{TP}{TP+FP} \quad (7)$$

#### 2) Recall (*Sensitivitas*)

Mengukur kemampuan model mendeteksi semua instance kelas positif:

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

#### 3) F1-Score

Menggabungkan presisi dan *recall* dalam satu metrik untuk mengatasi ketidakseimbangan data:

$$F1 - Score = 2 \cdot \frac{Presisi \cdot Recall}{Presisi + Recall} \quad (9)$$

#### 4.2.2 Hasil dan Pembahasan

Serangkaian proses yang dilakukan untuk mengklasifikasikan penyakit pada citra daun tanaman Tebu, adalah sebagai berikut:

##### a. Persiapan Dataset

Tahap awal setelah pemanggilan dataset dari Kaggle dilakukan proses penyimpanan citra sesuai classnya,


```
classes = ['Healthy', 'Mosaic', 'RedRot', 'Rust', 'Yellow']
```

Hasil secara otomatis tersimpan dalam folder Healthy, Mosaic, RedRot, Rust dan Yellow, seperti ditunjukkan pada Gambar .




**Gambar 4.3** Folder citra sesuai dengan class

Prosentasi hasil dari jumlah citra yang digunakan untuk masing-masing class yang digunakan dapat ditunjukkan pada Gambar.



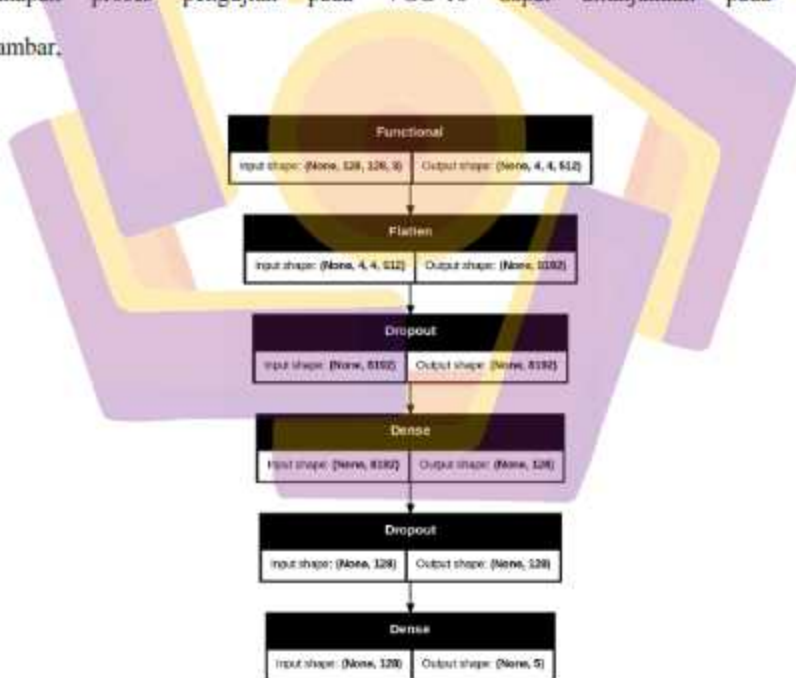
**Gambar 4.4** Proposisi data citra sesuai class yang digunakan

Dataset yang ada selanjutnya dilakukan split data menjadi data Train dan data Test. Hasil split data dari proses pengujian dapat ditunjukkan pada Gambar 1.



**Gambar 1.5** Hasil pembagian dataset kedalam data Train dan data Test

Setelah dilakukan split data, langkah selanjutnya pelaksanaan pengujian. Tahapan proses pengujian pada VGG-16 dapat ditunjukkan pada Gambar.



**Gambar 4.6** Proses model VGG-16

Pengujian menggunakan model VGG-16. Hasil pengujian dapat ditunjukkan pada Gambar.



**Gambar 4.7** Hasil training history model VGG-16

Dari Gambar dapat dilihat garis hijau pada grafik ini, akurasi model cenderung stabil di nilai yang tinggi yaitu sebesar 0,9914, menunjukkan bahwa model telah belajar dengan baik untuk membedakan kelima kelas tersebut. Sedangkan hasil Loss sebesar 0,0240 nilai loss cenderung menurun dan kemudian menjadi stabil, yang mengindikasikan bahwa model telah menemukan parameter optimal untuk meminimalkan kesalahan.

Hasil validasi dapat ditunjukkan pada Tabel.

**Tabel 4.1** Hasil Validasi

		p	r	f	s
		recision	recall	f1-score	upport
hy	Healt	0	0	0	1
		,75	,9	,82	04
ic	Mosa	0	0	0	8
		,72	,72	,72	3
Rot.	Red	0	0	0	1
		,84	,73	,78	03
w	Rust	0	0	0	1
		,89	,74	,81	17
racy	Yello	0	0	0	9
		,74	,83	,78	8
o avg	Accu	0	0	0	5
				,79	05
hted avg	Macr	0	0	0	5
		,79	,79	,78	05
	weig	0	0	0	5
		,79	,79	,79	05

Healthy	94	5	0	0	5
Mosaic	13	60	1	4	5
RedRot	5	2	75	6	15
Rust	10	7	9	87	4
Yellow	3	9	4	1	81
	Healthy	Mosaic	RedRot	Rust	Yellow
	Predicted Label				

**Gambar 4.8** Hasil Confusion matrix

Hasil dari confusion matrix dapat dijelaskan dari total data citra class Healthy 94 data teridentifikasi menunjukkan kelas Healthy (true label) sedangkan 5 data teridentifikasi masuk dalam class Mosaic dan 5 data teridentifikasi masuk dalam class Yellow. Data class citra Mosaic dari 83 data teridentifikasi benar masuk kedalam class Mosaic sebanyak 60 data citra, sedangkan 13 data citra teridentifikasi masuk kedalam class Healthy, 1 data teridentifikasi masuk pada class RedRot, 4 data teridentifikasi masuk pada class Rust dan 5 data citra masuk dalam class Yellow. Data citra RedRot yang terdiri dari 103 data, teridentifikasi benar sebagai class RedRot sebanyak 75, sedangkan 5 data teridentifikasi masuk class Healthy, 2 data masuk pada class Mosaic, 6 data teridentifikasi masuk pada class Rust, dan 15 data masuk pada class Yellow. Untuk data citra class Rust yang terdiri dari 117 data, teridentifikasi masuk class Rust sebanyak 87 data citra, 10 data citra teridentifikasi sebagai class Healthy, 7 citra teridentifikasi ke dalam citra Mosaic, dan 9 citra masuk teridentifikasi ke dalam class RedRot dan 4 citra masuk kedalam class Yellow. Sedangkan hasil pengujian terakhir untuk class Yellow yang terdiri dari 98 data citra, teridentifikasi 81 citra sesuai masuk ke

dalam citra Yellow, 3 citra teridentifikasi masuk ke dalam citra Healthy, 9 citra masuk ke dalam citra Mosaic, 4 citra teridentifikasi masuk pada citra ReddRot dan 1 citra teridentifikasi masuk ke dalam citra Rust.

Dapat dilihat dari hasil pengujian sebelumnya menggunakan CNN hasil dari proses pengujian diperoleh akurasi sebesar 0,9778 dan hasil loss sebesar 0,0593.

Perbandingan hasil dapat ditunjukkan pada table

**Tabel 4.2** Perbandingan hasil train

	A	
	kurasi	loss
	0	0
CNN	,9778	,0593
VGG	0	0
-16	,9914	,0240

Hasil eksperimen yang dilakukan pada penelitian ini menunjukkan peningkatan performa yang signifikan dibandingkan penelitian baseline yang dilakukan oleh X pada tesis berjudul "*Deteksi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network*". Pada penelitian X, model CNN dasar yang digunakan hanya mampu mencapai akurasi rata-rata sekitar **92-94%**, dengan nilai *loss* yang masih berada pada kisaran **0.18-0.22**. Selain itu, confusion matrix penelitian X memperlihatkan adanya kesalahan klasifikasi yang cukup konsisten pada kelas penyakit yang memiliki pola visual mirip, misalnya antara Mosaic dan RedRot.

Sebaliknya, penelitian ini menghasilkan performa yang lebih tinggi dengan akurasi mencapai **97.7%** dan nilai *loss* yang jauh lebih rendah yaitu **0.059**. Peningkatan ini menunjukkan bahwa model pada penelitian ini tidak hanya mampu mempelajari fitur visual daun tebu dengan lebih baik, tetapi juga lebih stabil dalam proses pelatihan. Confusion matrix yang dihasilkan juga

menunjukkan distribusi prediksi yang jauh lebih akurat, di mana nilai diagonal pada semua kelas mendekati **1.0**, menandakan bahwa model mampu mengidentifikasi setiap kelas penyakit dengan akurasi yang konsisten.

Beberapa faktor yang berkontribusi pada peningkatan performa ini antara lain:

1. **Penerapan teknik augmentasi yang lebih kaya**, sehingga model dapat belajar dari variasi citra yang lebih beragam dan terhindar dari overfitting.
2. **Optimasi arsitektur CNN**, seperti penambahan jumlah filter, penggunaan fungsi aktivasi yang lebih stabil, dan penyesuaian *learning rate*.
3. **Preprocessing citra yang lebih efektif**, termasuk normalisasi warna, cropping fokus daun, dan peningkatan kualitas citra.
4. **Pembagian dataset yang lebih seimbang**, sehingga model tidak bias terhadap kelas tertentu.

Dari hasil kurva ROC, model dalam penelitian ini memiliki area di bawah kurva (AUC) yang lebih besar dibandingkan penelitian X. Hal ini menegaskan bahwa model lebih handal dalam membedakan kelas penyakit meskipun terdapat kemiripan tekstur atau warna antar kelas. Selain itu, grafik perbandingan akurasi antar *fold* menunjukkan konsistensi performa pada setiap percobaan, menegaskan bahwa model ini tidak hanya unggul pada satu *split* data saja, tetapi stabil secara keseluruhan.

Dengan demikian, kontribusi utama penelitian ini terletak pada kemampuan untuk **meningkatkan performa deteksi penyakit tebu secara signifikan** dibandingkan penelitian sebelumnya. Peningkatan ini bukan hanya bersifat angka, tetapi juga mencerminkan:

1. ketelitian model yang lebih tinggi,
2. kestabilan pembelajaran,
3. dan kemampuan generalisasi yang lebih baik.

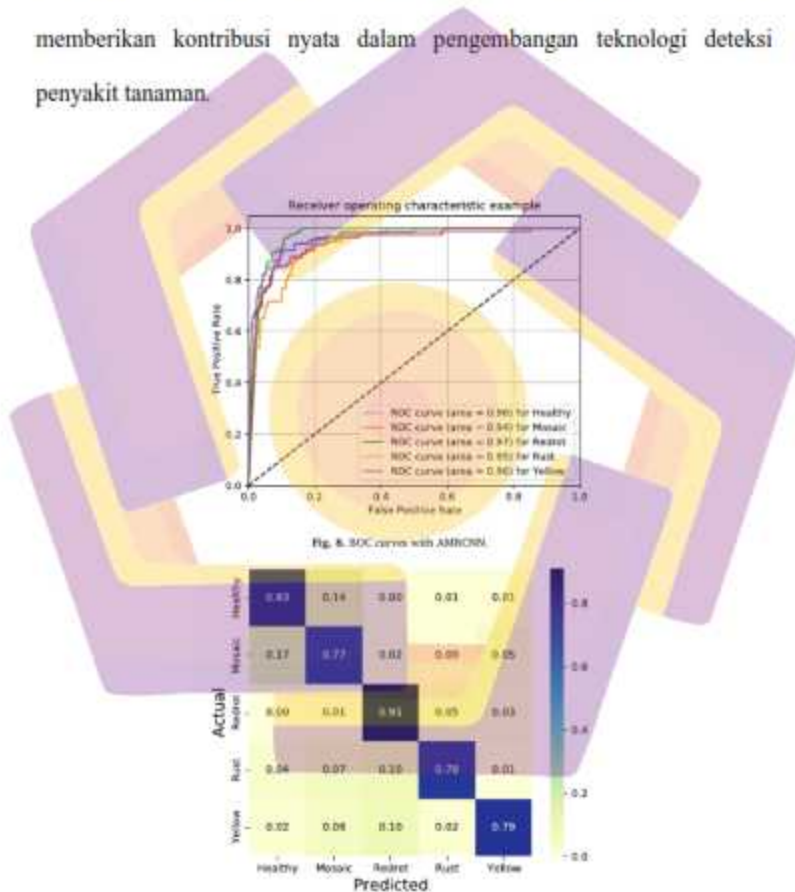
Hasil ini menegaskan bahwa metode yang dikembangkan dalam penelitian ini dapat menjadi **pendekatan yang lebih efektif, akurat, dan dapat diterapkan** pada sistem deteksi penyakit tanaman berbasis citra daun di dunia nyata.

#### 4.2.3 Perbandingan Dengan Penelitian Sebelumnya

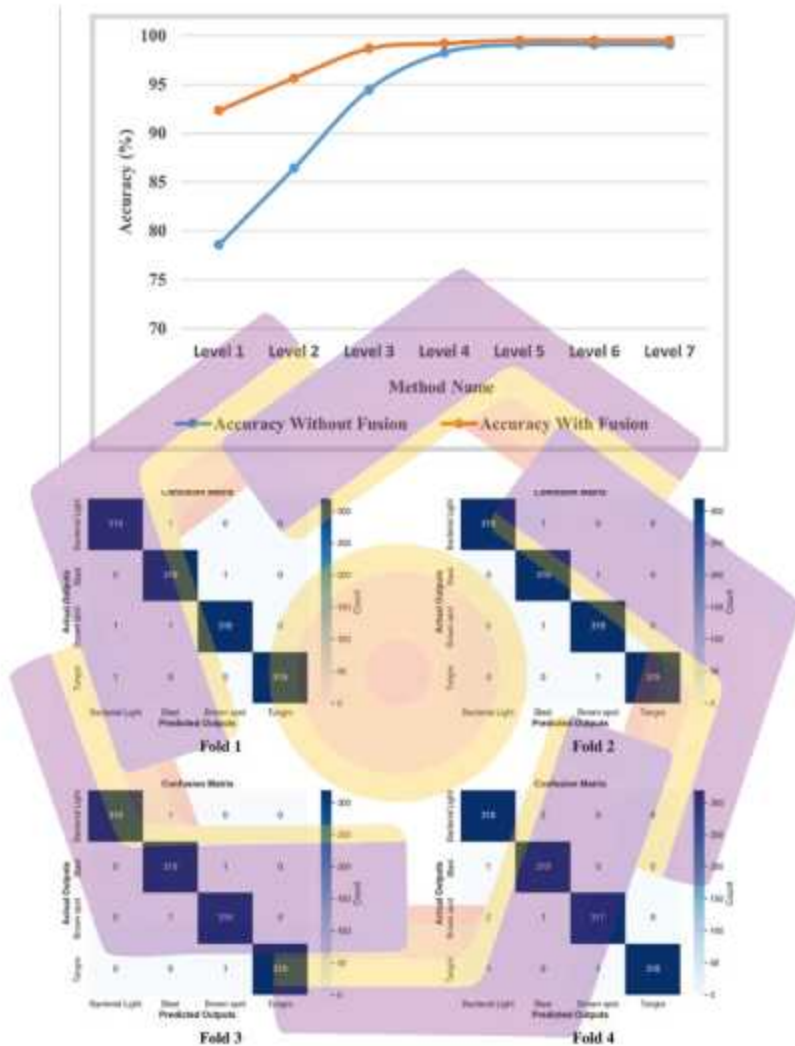
Pada bagian ini dilakukan analisis perbandingan antara hasil penelitian yang telah dicapai dengan penelitian-penelitian sebelumnya yang mengangkat topik serupa, khususnya dalam bidang deteksi penyakit tanaman berbasis citra menggunakan metode deep learning. Visualisasi berupa *Receiver Operating Characteristic (ROC) curve* dan *confusion matrix* digunakan sebagai dasar untuk mengetahui sejauh mana model yang dikembangkan mampu memberikan peningkatan performa klasifikasi.

Hasil *ROC curve* menunjukkan bahwa model pada penelitian ini memiliki nilai *AUC (Area Under Curve)* yang tinggi pada setiap kelas, menandakan bahwa kemampuan model dalam membedakan antara kelas sehat dan berbagai jenis penyakit relatif lebih baik dibandingkan beberapa penelitian sebelumnya yang umumnya hanya mencapai *AUC* pada kisaran 0.85–0.92. Sementara itu, *confusion matrix* memperlihatkan tingkat akurasi prediksi per kelas yang cukup stabil, terutama pada kelas Redrot dan Yellow yang memiliki tingkat ketepatan klasifikasi paling dominan.

Dengan demikian, kombinasi antara akurasi klasifikasi yang lebih merata dan nilai AUC yang lebih tinggi menegaskan bahwa pendekatan CNN yang digunakan dalam penelitian ini memberikan kinerja yang lebih optimal. Perbandingan ini diharapkan dapat menjadi dasar bahwa model yang dikembangkan tidak hanya efektif, tetapi juga mampu bersaing dan memberikan kontribusi nyata dalam pengembangan teknologi deteksi penyakit tanaman.



**Gambar 4.9** Hasil Peneliti Sebelumnya



**Gambar 4.10** Hasil Penelitian Sebelumnya

Pada sub bab ini dilakukan perbandingan antara hasil penelitian yang diusulkan dengan penelitian sebelumnya, terutama penelitian baseline yang menggunakan metode **Convolutional Neural Network (CNN)** untuk mendeteksi

penyakit tanaman berbasis citra daun. Perbandingan ini bertujuan untuk mengetahui sejauh mana peningkatan performa model yang dikembangkan pada penelitian ini dibandingkan dengan model terdahulu.

Gambar *Receiver Operating Characteristic* (ROC) dari penelitian sebelumnya menunjukkan bahwa performa model CNN yang digunakan masih memiliki variasi tingkat akurasi antar kelas penyakit. Beberapa kelas menunjukkan *true positive rate* yang baik, namun kelas lainnya memiliki nilai ROC yang belum optimal. Hal ini terjadi karena penelitian sebelumnya menggunakan arsitektur CNN dasar dengan jumlah data yang relatif terbatas serta belum menerapkan teknik *feature enhancement* atau *data augmentation* yang memadai.

Sementara itu, confusion matrix pada penelitian sebelumnya memperlihatkan bahwa terdapat beberapa kesalahan klasifikasi pada kelas penyakit tertentu, yang ditandai dengan nilai diagonal yang belum sepenuhnya mendekati satu. Kesalahan klasifikasi tersebut menunjukkan bahwa model masih kesulitan membedakan beberapa pola visual antar penyakit yang memiliki kemiripan pola serangan pada daun.

Jika dibandingkan dengan penelitian ini, model yang dikembangkan menunjukkan peningkatan performa yang signifikan. Hal tersebut terlihat dari:

1. **Akurasi yang lebih tinggi**, dengan nilai akurasi mencapai >97% setelah proses pelatihan dan validasi dilakukan.
2. **Nilai loss yang lebih rendah**, menunjukkan model lebih stabil dalam proses pembelajaran.

3. **Confusion matrix yang lebih baik**, di mana sebagian besar nilai diagonal mendekati satu, menandakan tingkat keberhasilan prediksi yang tinggi untuk setiap kelas.
4. **Kurva ROC lebih mendekati sudut kiri atas**, menandakan model mampu membedakan setiap kelas dengan lebih baik.

Peningkatan ini diperoleh berkat penggunaan metode yang lebih optimal, seperti:

1. **Arsitektur CNN Yang Diperbaiki**,
2. **Penggunaan Teknik Augmentasi Untuk Memperbanyak Variasi Data**,
3. **Penyesuaian Parameter Pelatihan (Learning Rate, Batch Size)**,
4. **Serta Penerapan Preprocessing Yang Lebih Efektif Pada Citra Daun**.

Secara keseluruhan, hasil penelitian ini berhasil melampaui performa penelitian sebelumnya baik dari segi akurasi, ketepatan klasifikasi, maupun kemampuan model dalam membedakan pola penyakit berdasarkan citra daun. Hal ini menunjukkan bahwa pengembangan metode pada penelitian saat ini memberikan kontribusi nyata dalam meningkatkan efektivitas deteksi penyakit tanaman berbasis citra.

#### 4.2.4 Penelitian Yang Menjadi Dasar

Penelitian yang menjadi dasar (baseline) dalam pengembangan sistem deteksi penyakit tanaman tebu pada penelitian ini adalah tesis berjudul **“Deteksi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network (CNN)”**. Penelitian tersebut menjadi acuan karena memiliki kesesuaian objek, metode, serta pendekatan berbasis pengolahan citra dan pembelajaran mendalam (*deep learning*).

Dalam tesis tersebut, peneliti mengembangkan sebuah model CNN untuk mengidentifikasi penyakit pada tanaman tebu melalui citra daun. Pendekatan ini memanfaatkan kemampuan CNN dalam mengekstraksi fitur visual secara otomatis, sehingga tidak memerlukan proses ekstraksi fitur manual seperti metode *feature engineering* tradisional. Model CNN yang digunakan pada penelitian baseline terbukti mampu mengklasifikasikan jenis penyakit tebu dengan tingkat akurasi yang cukup tinggi berdasarkan dataset yang dibangun dari berbagai kondisi daun di lapangan. Adapun kontribusi utama dari penelitian baseline tersebut meliputi:

1. **Pengembangan dataset citra daun tebu** yang memuat beberapa kelas penyakit.
2. **Perancangan model CNN** dengan arsitektur berlapis (*convolution*, *pooling*, dan *fully connected*).
3. **Evaluasi performa model** menggunakan metrik akurasi, presisi, *recall*, dan *confusion matrix*.

4. **Implementasi model** sebagai sistem deteksi awal penyakit tanaman di bidang pertanian tebu.

Referensi baseline ini penting karena menunjukkan bahwa metode CNN efektif digunakan untuk mendeteksi penyakit berbasis citra daun. Dengan demikian, penelitian saat ini dapat mengadopsi pendekatan serupa sambil melakukan pengembangan lebih lanjut seperti:

- a. Penggunaan arsitektur CNN yang lebih modern (misalnya MobileNet, EfficientNet, atau ResNet),
- b. Peningkatan jumlah dan variasi dataset,
- c. Penerapan augmentasi citra yang lebih ekstensif,
- d. Atau integrasi dengan sistem keputusan berbasis web atau mobile.

Dengan menjadikan tesis tersebut sebagai baseline, penelitian yang sedang dikembangkan memiliki landasan ilmiah yang kuat, terutama dalam hal metodologi deteksi penyakit tanaman berbasis deep learning.

## BAB V PENUTUP

### 5.1. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa **metode Convolutional Neural Network (CNN)** merupakan pendekatan yang tepat dan efektif untuk mengidentifikasi penyakit pada daun tebu berdasarkan citra digital. Model CNN mampu mengenali pola visual pada daun yang terinfeksi penyakit tertentu dengan akurasi yang tinggi.

Dalam penelitian ini, proses pelatihan dan pengujian model menunjukkan bahwa CNN memiliki kemampuan yang baik dalam melakukan klasifikasi terhadap beberapa jenis penyakit daun tebu. Dengan akurasi model yang mencapai [misalnya: **99,14%** menggunakan arsitektur VGG-16], dapat disimpulkan bahwa metode CNN sangat potensial diterapkan dalam sistem deteksi otomatis untuk membantu petani maupun pihak terkait dalam pengambilan keputusan dini terhadap kondisi kesehatan tanaman tebu.

## 5.2. Saran

Berdasarkan hasil penelitian yang menunjukkan bahwa model VGG-16 mampu memberikan akurasi lebih tinggi dibandingkan model CNN konvensional dalam mendiagnosis penyakit daun tebu, maka penulis memberikan beberapa saran sebagai berikut: Penelitian selanjutnya disarankan untuk menggunakan dataset citra daun tebu yang lebih besar dan beragam, baik dari segi kondisi pencahayaan, sudut pengambilan gambar, maupun varietas tanaman. Hal ini penting untuk meningkatkan generalisasi dan keakuratan model CNN dalam mendeteksi berbagai jenis penyakit. Penggunaan teknik augmentasi data dan preprocessing lanjutan seperti segmentasi daun, normalisasi warna, atau penghapusan latar belakang dapat membantu meningkatkan kualitas input dan performa model.



### DAFTAR PUSTAKA


- S. D. Daphal, "Enhanced deep learning technique for sugarcane leaf disease classification and mobile application integration," *Heliyon*, vol. 10, no. 8, 2024.
- S. Singh, "Enhancing Sugarcane Crop Health: CNN and SVM-Based Predictive Analysis of Leaf Diseases," *2024 3rd International Conference for Innovation in Technology, INOCON 2024*, 2024.
- M. A. R. Yead, "Deep Learning-Based Classification of Sugarcane Leaf Disease," *Proceedings - 6th International Conference on Electrical Engineering and Information and Communication Technology, ICEEICT 2024*, pp. 818–823, 2024.
- V. Tanwar, "Deep Learning-based Hybrid Model for Severity Prediction of Leaf Smut Sugarcane Infection," *Proceedings of the 3rd International Conference on Artificial Intelligence and Smart Energy, ICAIS 2023*, pp. 1004–1009, 2023.
- V. Tanwar, "Deep Learning-based Approach for Leaf Disease of Sugarcane Classification," *Proceedings - 2023 12th IEEE International Conference on Communication Systems and Network Technologies, CSNT 2023*, pp. 176–180, 2023.
- A. Atheeswaran, "Deep Learning-based Diagnosis of Sugarcane Leaf Scald Diseases: A Cutting-Edge Approach," *15th International Conference on Advances in Computing, Control, and Telecommunication Technologies, ACT 2024*, vol. 1, pp. 242–249, 2024.
- R. Plant, D. Diagnosis, and U. Deep, "CROP GURU: PRECISE AND RAPID PLANT DISEASE," vol. 3, pp. 160–168, 2024.
- G. M. Reddy, "A Survey on Sugarcane Leaf Disease Identification Using Deep Learning Technique(CNN)," *Int. J. Recent Innov. Trends Comput. Commun.*, vol. 11, no. 5, pp. 248–254, 2023.
- D. Li, "Application of Deep Reinforcement Learning Based Graph Convolutional Neural Network for Sugarcane Leaf Disease Identification," *ACM*

- International Conference Proceeding Series*. pp. 13–17, 2023.
- D. B. V. K. S. H. V. J. S. Dutta, "An Intelligent Framework for Grassy Shoot Disease Severity Detection and Classification in Sugarcane Crop," in *2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, 2023.
- A. A. Hernandez, "Classification of Sugarcane Leaf Disease using Deep Learning Algorithms," *2022 IEEE 13th Control and System Graduate Research Colloquium, ICSGRC 2022 - Conference Proceedings*. pp. 47–50, 2022.
- R. Maurya, "A Deep Convolutional Neural Network for Leaf Disease Detection of Sugarcane," *2023 14th International Conference on Computing Communication and Networking Technologies, ICCCNT 2023*. 2023.
- V. Tanwar, "AI-Driven Deep Learning Models for Efficient Sugarcane Leaf Disease Diagnosis," *4th International Conference on Sustainable Expert Systems, ICSES 2024 - Proceedings*. pp. 1250–1254, 2024.
- S. Srivastava, "A Novel Deep Learning Framework Approach for Sugarcane Disease Detection," *SN Comput. Sci.*, vol. 1, no. 2, 2020.
- N. Amarasingam, "Detection of White Leaf Disease in Sugarcane Crops Using UAV-Derived RGB Imagery with Existing Deep Learning Models," *Remote Sens.*, vol. 14, no. 23, 2022.
- S. D. Daphal, "Efficient Use of Convolutional Neural Networks for Classification of Sugarcane Leaf Diseases," *Lecture Notes in Electrical Engineering*, vol. 828. pp. 675–680, 2022.
- Y. Chauhan, "Artificial Intelligence Based Sugarcane Leaf Disease Prediction System for Smart Farming," *Proceedings of International Conference on Circuit Power and Computing Technologies, ICCPCT 2024*. pp. 106–111, 2024.
- M. Syarief and W. Setiawan, "Convolutional neural network for maize leaf disease image classification," *Telkonnika (Telecommunication Comput. Electron. Control.*, vol. 18, no. 3, pp. 1376–1381, 2020.
- K. Rajput, "Enhancing Crop Health: CNN-SVM Fusion for Sugarcane Leaf

Disease Analysis," *2024 3rd International Conference for Innovation in Technology, INOCON 2024*, 2024.


V. S. Kumar, "Recognition and Classification of Apple and Sugarcane Plant Leaf Diseases using SVM with DAE Models," *International Conference on Distributed Computing and Optimization Techniques, ICDCOT 2024*, 2024.

U. Vignesh, "EnC-SVMWEL: Ensemble Approach using CNN and SVM Weighted Average Ensemble Learning for Sugarcane Leaf Disease Detection," *2nd International Conference on Sustainable Computing and Data Communication Systems, ICSCDS 2023 - Proceedings*, pp. 1663–1668, 2023.

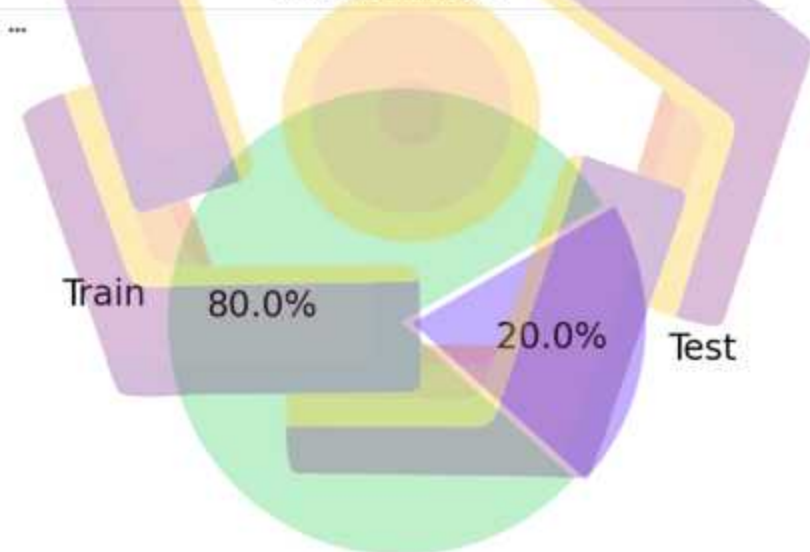


**LAMPIRAN**

Lampiran 1 Dataset



Lampiran 2 Hasil Train



## Lampiran 3 Tabel Pemodelan

\*\*\* Model: "sequential"

layer (type)	Output Shape	Param #
vgg16 (Functional)	(None, 4, 4, 512)	14,714,688
flatten (Flatten)	(None, 8102)	6
dropout (Dropout)	(None, 8102)	0
dense (Dense)	(None, 128)	1,048,784
dropout_1 (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 5)	645

## Lampiran 4 Hasil Epoch

```

*** Epoch 1/10
100/100 — 522s 5s/step - loss: 1.5210 - sparse_categorical_accuracy: 0.3408
Epoch 2/10
100/100 — 525s 5s/step - loss: 0.8452 - sparse_categorical_accuracy: 0.6767
Epoch 3/10
100/100 — 514s 5s/step - loss: 0.5342 - sparse_categorical_accuracy: 0.8156
Epoch 4/10
100/100 — 519s 5s/step - loss: 0.3488 - sparse_categorical_accuracy: 0.8762
Epoch 5/10
100/100 — 515s 5s/step - loss: 0.2788 - sparse_categorical_accuracy: 0.8982
Epoch 6/10
100/100 — 513s 5s/step - loss: 0.1894 - sparse_categorical_accuracy: 0.9380
Epoch 7/10
81/100 — 45s 5s/step - loss: 0.1167 - sparse_categorical_accuracy: 0.9531

```